

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA QUÍMICA

DEPARTAMENTO DE SISTEMAS DE PROCESSOS QUÍMICOS E INFORMÁTICA

FCC: CONTROLE PREDITIVO E IDENTIFICAÇÃO VIA REDES NEURAIS

Autor: William Gonçalves Vieira

Orientadora: Dra. Ana Maria Frattini Fileti

Co-Orientador: Dr. Florival Rodrigues de Carvalho

Tese de Doutorado apresentada à Faculdade de Engenharia Química como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Química.

Campinas – São Paulo  
Dezembro de 2002

UNICAMP  
BIBLIOTECA CENTRAL  
SEÇÃO CIRCULANTE

UNICAMP  
BIBLIOTECA CENTRAL

UNIDADE	BC
Nº CHAMADA	T/UNICAMP
	V673f
V	EX
TOMBO BCI	53249
PROC.	124103
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	R\$ 11,00
DATA	23/04/03
Nº CPD	

CM00182262-2

8 ID 289753  
 FICHA CATALOGRÁFICA ELABORADA PELA  
 BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

V673f      Vieira, William Gonçalves  
             FCC: controle preditivo e identificação via redes neurais / William Gonçalves Vieira. --Campinas, SP: [s.n.], 2002.

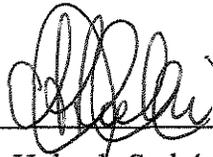
            Orientadores: Ana Maria Frattini Fileti e Florival Rodrigues de Carvalho.  
             Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química.

            1. Craqueamento catalítico. 2. Redes neurais (Computação). 3. Controle preditivo. I. Fileti, Ana Maria Frattini. II. Carvalho, Florival Rodrigues de. III. Universidade Estadual de Campinas. Faculdade de Engenharia Química. IV. Título.

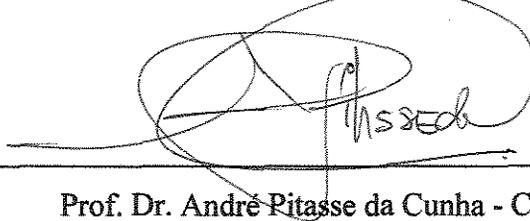
Tese de Doutorado defendida por William Gonçalves Vieira e aprovada em 06 de dezembro de 2002 pela banca examinadora constituída pelos doutores:



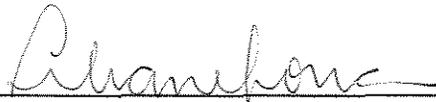
Prof<sup>ª</sup>. Dr<sup>ª</sup>. Ana Maria Frattini Fileti (Orientadora) – FEQ/UNICAMP



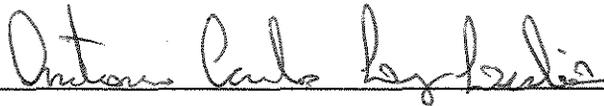
Prof<sup>ª</sup>. Dr<sup>ª</sup>. Cristiane Holanda Sodr  – CTEC/UFAL



Prof. Dr. Andr  Pitasse da Cunha - CSN

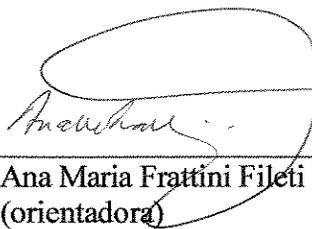


Prof<sup>ª</sup>. Dr<sup>ª</sup>. Lilians Maria Ferrareso Lona – FEQ/UNICAMP



Prof. Dr. Ant nio Carlos Luz Lisboa – FEQ/UNICAMP

Este exemplar corresponde à versão final da Tese de Doutorado em  
Engenharia Química.



Handwritten signature of Ana Maria Frattini Fileti, written in black ink. The signature is stylized and cursive, with a large loop at the top. It is positioned above a horizontal line.

---

Profa. Dra. Ana Maria Frattini Fileti  
(orientadora)

À esposa e filhos  
Célia, Fábio, Leandro e Vinícius

## **AGRADECIMENTOS**

A Deus acima de tudo, por me permitir viver e assim realizar.

À minha amada esposa pelo apoio e incentivo durante toda esta jornada; sem ela eu tenderia ao fracasso.

Aos meus filhos por sua paciência, apoio e compreensão durante minhas ausências do convívio familiar.

À minha orientadora Dra. Ana Frattini, pela sua experiência, suas críticas e sugestões bem vindas e necessárias à realização desta Tese.

Ao co-orientador, Dr. Florival, por sua grande ajuda e total apoio, sem o qual eu não conseguiria terminar esta tarefa.

Ao Professor Dr. Maurício Bezerra, pela autorização do uso de suas rotinas computacionais.

À colega Vivianni, pela amizade e apoio.

Aos professores e funcionários da UFPE pela disponibilização de seu precioso tempo.

Ao Departamento de Engenharia Química da Universidade Federal de Pernambuco, por ceder espaço, equipamentos e materiais necessários.

A Universidade Federal de Alagoas pela liberação para realização desta Tese.

A CAPES/PIDCT pela ajuda financeira na concessão da bolsa de doutorado.

**Resumo:** A unidade de Craqueamento Catalítico em Leito Fluido – FCC, modelo Kellogg Orthoflow F., representa um processo de refino de petróleo apresentando característica altamente não linear, possuindo fortes interações entre as variáveis de produção, e condições de operação extremamente severas. Essas unidades são constituídas basicamente de duas seções: uma de reação catalítica na qual ocorrem as reações de quebra de cadeia hidrocarbônica e também há formação de coque, desativando o catalisador; e outra seção onde ocorre a regeneração do catalisador desativado. O objetivo dessa unidade é transformar produtos de elevado peso molecular, que apresentam baixo valor agregado, em compostos de elevado valor comercial. As unidades FCC, devido às condições severas de operação, necessitam de um controle rigoroso de determinadas variáveis operacionais. Apesar de existirem instalados controladores avançados baseados em modelos de convolução, freqüentemente essas unidades são reguladas por meio de controladores PID padrões e também através de controle manual baseado no conhecimento de operadores das refinarias. O presente estudo tem como objetivo desenvolver um controlador preditivo multivariável (*Multivariable Predictive Control - MPC*) para ser implementado na unidade FCC, utilizando Redes Neurais Artificiais (RNA) como modelo interno do controlador. Inicialmente é previsto realizar a identificação do processo da FCC em RNA, obedecendo a seguinte estratégia: usando um modelo fenomenológico que representa a unidade industrial, e partindo de um estado inicial são aplicados diversos degraus nas variáveis manipuladas analisando as respostas nas variáveis controladas do processo. A partir destas simulações são gerados diversos conjuntos de dados divididos em grupos de treinamento, validação e teste. Diversas redes neurais do tipo multicamada *feedforward* são então criadas para representar o modelo fenomenológico, sendo selecionada aquela que apresenta melhor desempenho, quando comparada com o modelo. A configuração da RNA escolhida como modelo interno foi 8x15x4 (camadas de entrada, escondida e de saída, respectivamente) apresentando um erro relativo máximo de 1% quando comparado com os resultados do modelo rigoroso. Posteriormente, foi previsto desenvolver um controlador preditivo multivariável usando como modelo interno esta rede selecionada. Este controlador foi implementado dentro da rotina do modelo fenomenológico, sendo então realizados testes para verificar seu desempenho, comparando o resultado com o sistema aberto e também com o controlador DMC (*Dynamic Matrix Control*) existente. Diversos horizontes de predição e controle foram analisados, sendo selecionados aqueles que apresentaram melhor desempenho. Foi introduzido um ruído nos sinais do modelo fenomenológico para testar a robustez do controlador proposto. O controlador apresentou bom desempenho mesmo na presença de ruídos de 1,5%, levando sempre as variáveis controladas para seus valores de referência, o que comprova sua robustez. Baseados nestes resultados, conclui-se que um controlador preditivo multivariável baseado em RNA é perfeitamente capaz de controlar um sistema não linear de porte do FCC, onde elevada interação entre suas variáveis operacionais e fortes restrições estão presentes. Isto nos permite extrapolar que são boas as expectativas para uma futura utilização na unidade industrial, principalmente devido à sua simplicidade, robustez e facilidade de implementação, a despeito da dificuldade de sintonia do controlador.

**Palavras Chave:** FCC, Redes Neurais Artificiais, Controlador preditivo multivariável.

**Abstract:** The Fluid Cracking Catalytic unit - FCC, Kellogg Orthoflow F. model, represents a very strong nonlinear process, with severe interactions among the process variables, and extremely severe operation conditions. The unit is composed of two sections: one is the catalytic reaction, where the hydrocarbon breaks chain reactions and coke deposition take place becoming the catalyst inactive, and the other where the catalyst regeneration happens. The objective is to transform products derived from petroleum, with high molecular weight and low added value, into products with higher profit. Due to the severe operation conditions, rigorous control of some variable is needed. In spite of the existence of advanced control based on a convolution model, in practice, FCC units are frequently regulated by standard PID controllers, and also through manual control actions based on the knowledge of the refinery operators. The objective of this study is to develop a Multivariable Predictive Control (MPC) to be implemented in the FCC unit, using the Artificial Neural Networks (ANN) as internal model. Initially, the process identification in ANN of the FCC was done by the following strategy: an initial state was first achieved using numerical simulations based on the phenomenological model. Then, several steps changes were applied to the manipulated variables and the response in the controlled variables were monitored and recorded. From these simulations, several groups of data were generated for training, validation and testing. The Neural Network of multilayer feedforward type were created to represent the phenomenological model, being selected the one that better represents the phenomenological model. The ANN configuration chosen to be the internal model was 8x15x4 (Input x Hidden x Output) architecture, with a maximum relative error below 1% when comparing the results with the phenomenological model results. Later on, it was developed a multivariable predictive control based on this internal model. This control was implemented inside the routine of the phenomenological model. The performance tests were evaluated comparing the results with the open system and with the Dynamics Matrix Control (DMC). Several prediction and control horizons were analyzed. The ANN control presented good performance even in the presence of noise of 1,5% of intensity, taking back the controlled variables to its setpoints, proving its robustness. Based on these results, a multivariable predictive control based on ANN showed be perfectly able to control a nonlinear system like a FCC unit, where high interactions among process variables, and strong restriction conditions exists. This allows us to have good expectations for a future use in the industrial unit, mainly due to its simplicity, robustness and facility of use, in spite of the difficulty of tune control.

**Keywords:** FCC, Artificial Neural Networks, Multivariable Predictive Control.

## SUMÁRIO

LISTA DE FIGURAS.....	xi
LISTA DE TABELAS.....	xiii
NOMENCLATURA.....	xiv
<b>CAPÍTULO I</b>	
INTRODUÇÃO.....	1
1.1 Objetivos.....	1
1.2 Estrutura do trabalho.....	4
<b>CAPÍTULO II</b>	
REVISÃO BIBLIOGRÁFICA.....	7
2.1 Unidade de Craqueamento Catalítico.....	7
2.2 Redes Neurais Artificiais.....	15
2.2.1 <i>Histórico</i> .....	15
2.2.2 <i>As Redes Neurais Artificiais</i> .....	16
2.3 Proposta da Tese.....	25
<b>CAPÍTULO III</b>	
MODELAGEM MATEMÁTICA DO PROCESSO.....	27
3.1 Modelos que representam a unidade de FCC.....	27
3.2 Processo de Craqueamento Catalítico em Leito Fluido.....	28
3.2.1 <i>Descrição de operação da unidade</i> .....	30
3.2.2 <i>Estratégia de controle do FCC</i> .....	32
3.3 As Redes Neurais Artificiais.....	35
3.3.1 <i>Arquitetura das redes multicamadas</i> .....	36
3.3.2 <i>Método de Treinamento Backpropagation</i> .....	43
3.3.3 <i>Identificação em Redes Neurais Artificiais</i> .....	48
3.4 Aplicação das redes neurais no FCC.....	52
3.5 Controle Preditivo com Modelo.....	57
3.5.1 <i>Controle do FCC utilizando como modelo as Redes Neurais</i> .....	59

## CAPÍTULO IV

<b>RESULTADOS</b> .....	65
<b>4.1 Identificação do modelo fenomenológico via Redes Neurais Artificiais</b> .....	65
<i>4.1.1 Obtenção dos conjuntos de dados a partir do modelo fenomenológico</i> .....	65
<i>4.1.2 Obtenção das condições do treinamento das redes</i> .....	66
<i>4.1.3 Modelo escolhido em rede neural para representar o processo de FCC</i> .....	71
<b>4.2 Controlador Preditivo usando as RNA como modelo interno</b> .....	78
<i>4.2.1 Comportamento do modelo fenomenológico em malha aberta</i> .....	82
<i>4.2.2 Resposta utilizando DMC (Dynamic Matrix Control)</i> .....	82
<i>4.2.3 Testes de desempenho do controlador proposto</i> .....	83
<i>4.2.3.1 Problema regulador</i> .....	83
<i>4.2.3.2 Problema regulador para uma perturbação agressiva</i> .....	87
<i>4.2.3.3 Mudança de qualidade da carga</i> .....	89
<i>4.2.3.4 Problema servo-regulador</i> .....	92
<i>4.2.3.5 Comparação com o controle DMC</i> .....	95

## CAPÍTULO V

<b>CONCLUSÕES E SUGESTÕES</b> .....	99
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	103
<b>ANEXOS</b>	
<b>ANEXO A ALGORITMO DE TREINAMENTO VIA RETROPROPAGAÇÃO (BACKPROPAGATION)</b> .....	119
<b>ANEXO B CÁLCULO DOS ELEMENTOS DE <math>\underline{VE}(W)</math> DO MÉTODO <i>STEEPEST DESCENT</i></b> .	121
<b>ANEXO C ALGORITMO DO CONTROLE PREDITIVO UTILIZANDO REDES NEURAIS</b> .	123
<b>ANEXO D MODELO DINÂMICO DO CONVERSOR</b> .....	125
<b>ANEXO E ALGORITMO DE IDENTIFICAÇÃO DO PROCESSO EM REDES NEURAIS ARTIFICIAIS</b> .....	135
<b>APÊNDICES</b> .....	137
<b>APÊNDICE 1 IDENTIFICAÇÃO DE PROCESSO DE UMA UNIDADE DE CRAQUEAMENTO CATALÍTICO UTILIZANDO REDE NEURAL</b> .....	141

<b>APÊNDICE 2 FCC UNIT: MULTIVARIABLE PREDICTIVE CONTROL WITH ANN MODELING. ....</b>	<b>157</b>
<b>APÊNDICE 3 FCC: UMA ALTERNATIVA DE CONTROLE PREDITIVO MULTIVARIÁVEL POR REDE DINÂMICA. ....</b>	<b>173</b>
<b>APÊNDICE 4 FCC: PROCESS IDENTIFICATION THROUGH ARTIFICIAL NEURAL NETWORKS .....</b>	<b>183</b>

## LISTA DE FIGURAS

Figura 3.1 Circulação de Catalisador em uma Unidade de Craqueamento Catalítico .....	29
Figura 3.2 Desenho esquemático da Unidade de Craqueamento Catalítico da <i>Kellogg Orthoflow F.</i> pertencente à Refinaria Henrique Lage, situada em S. José dos Campos – SP .....	31
Figura 3.3 Esquema do controle convencional da unidade de Craqueamento Catalítico .....	32
Figura 3.4 Formas de conexão dos neurônios artificiais. 1, 2 e 3 representam as camadas de entrada, intermediária ou escondida e de saída, respectivamente .....	37
Figura 3.5 Redes multicamadas <i>feedforward</i> exemplificado para o caso de 3 camadas (a) parcialmente conectada e (b) totalmente conectada .....	38
Figura 3.6 Representação esquemática de um neurônio qualquer pertencente à camada $k+1$ .....	40
Figura 3.7 Exemplos de função de ativação do neurônio tipo <i>sigmoidal</i> (BAUGHMAN & LIU, 1995) .....	42
Figura 3.8 Estrutura das RNA para $n = m = 1$ à esquerda e para $n = m = 2$ à direita para um sistema SISO (SANTOS, 2000b) .....	51
Figura 3.9 Opções de identificação do processo utilizando rede neural para capturar o comportamento dinâmico; método série-paralelo e método paralelo .....	52
Figura 3.10 Esboço da representação da rede neural proposta com arquitetura $8 \times 15 \times 4$ , referente ao sistema MIMO mais complexo. Os <i>Bias</i> não estão apresentados por problemas de limitação de espaço na figura .....	57
Figura 3.11 Esboço ilustrativo da ação de controle preditivo considerando apenas uma variável controlada (sistema SISO) .....	58
Figura 3.12 Esquema genérico proposto para um Controlador Preditivo com Modelo utilizando Redes Neurais Artificiais (DE SOUZA JR., 1993) .....	60
Figura 3.13 Esboço do sistema de controle proposto, via Redes Neurais Artificiais, para acoplamento ao controle convencional da unidade FCC .....	63
Figura 4.1 Resposta na Temperatura da Fase Densa do primeiro estágio do regenerador, TRG1, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura $8 \times 15 \times 4$ na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua) .....	73
Figura 4.2 Resposta na Temperatura da Fase Densa do segundo estágio do regenerador, TRG2, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura $8 \times 15 \times 4$ na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua) .....	73
Figura 4.3 Resposta na Severidade da Reação Catalítica, variável SEV, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura $8 \times 15 \times 4$ na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua) .....	74
Figura 4.4 Resposta na Temperatura de Saída do <i>Riser</i> , TRX, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura $8 \times 15 \times 4$ na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua) .....	74

Figura 4.5 Degraus impostos nas variáveis manipuladas: Temperatura da Alimentação do Reator, TFP (esquerda), e Vazão de Ar para o Regenerador, RAI (direita), nas etapas de treinamento e validação da rede neural, na configuração 8x15x4 (vide Tabela 4.2) . . . . .	75
Figura 4.6 Degraus impostos na variável manipulada: Vazão de Alimentação do Reator, RTF (esquerda) e Vazão de Catalisador Regenerado, CTCV (direita), nas etapas de treinamento e validação da rede neural na configuração 8x15x4 (vide Tabela 4.2) . . . . .	76
Figura 4.7 Comparação entre os resultados obtidos da variável TRG1 (esquerda) e TRG2 (direita), pelo modelo em redes neurais com ruído e os resultados obtidos pelo modelo rigoroso, aplicando degraus nas variáveis TFP, RAI, RTF e CTCV, conforme Tabela 4.3, configuração 2 . . . . .	77
Figura 4.8 Comparação entre os resultados obtidos da variável severidade da reação catalítica (esquerda) e TRX (direita), pelo modelo em redes neurais com ruído e pelo modelo rigoroso, com os degraus impostos nas variáveis TFP, RAI, RTF e CTCV (vide Tabela 4.2, configuração 2) . . . . .	78
Figura 4.9 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis controladas: Temperaturas das Fases Densas do Regenerador, primeiro estágio, TRG1 (esquerda) e segundo estágio, TRG2 (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8% . . . . .	84
Figura 4.10 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis controladas: Severidade da Reação Catalítica, SEV (esquerda) e Temperatura de Saída do <i>Riser</i> , TRX (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8% . . . . .	85
Figura 4.11 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis associadas: Temperatura da Fase Diluída do segundo estágio do Regenerador – TD2 (esquerda) e Temperatura de Saída Geral do Regenerador - TDG (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8% . . . . .	86
Figura 4.12 Problema Regulador. Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização manter a variável RTF fixa. Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8% . . . . .	86
Figura 4.13 Problema Regulador. Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de controle manter a variável RTF fixa. Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8% . . . . .	87
Figura 4.14 Resultados obtidos da ação do controlador (linha cheia) e os resultados do sistema aberto (linha tracejada). Variáveis controladas: Temperatura da Fase Densa do primeiro estágio do Regenerador, TRG1 (esquerda) e Temperatura da Fase Densa do segundo estágio do Regenerador, TRG2 (direita). Perturbação: variável SETPDCV intensidade de +7,7% . . . . .	88
Figura 4.15 Resultados obtidos da ação do controlador (linha cheia) e os resultados do sistema aberto (linha tracejada). Variáveis controladas: Severidade da Reação Catalítica (esquerda) e Temperatura de Saída do <i>Riser</i> , TRX (direita). Perturbação: variável SETPDCV intensidade de +7,7% . . . . .	88
Figura 4.16 Ações do controlador nas variáveis manipuladas, RAI e CTCV, assumindo como otimização manter a variável RTF fixa. Resposta à perturbação degrau de +7,7% no Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV . . . . .	89
Figura 4.17 Ações do controlador nas variáveis manipuladas, RTF e TFP, assumindo como otimização manter a variável RTF fixa. Resposta à perturbação degrau de +7,7% no Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV . . . . .	89

Figura 4.18 Resultados obtidos do teste de simulação de mudança de qualidade de carga, comparando sistema aberto (linha tracejada) e controlador (linha cheia). Variáveis controladas: TRG1 (esquerda) e TRG2 (direita). Perturbação: variável KCC, intensidade +10%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: minimizar a produção .....	90
Figura 4.19 Resultados obtidos do teste de simulação de mudança de qualidade de carga, comparando sistema aberto (linha tracejada) e controlador (linha cheia). Variáveis controladas: Severidade da Reação Catalítica, SEV (esquerda) e Temperatura de Saída do <i>Riser</i> , TRX (direita). Perturbação: variável KCC com intensidade de +10%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: minimizar a produção .....	91
Figura 4.20 Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização minimizar a produção, como resposta à uma perturbação na variável KCC com intensidade de +10%, com inserção de ruído de 1,5% nas variáveis controladas .....	92
Figura 4.21 Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de otimização minimizar a produção, como resposta à uma perturbação na variável KCC com intensidade de +10%, com inserção de ruído de 1,5% nas variáveis controladas .....	92
Figura 4.22 Resultados obtidos do teste de mudança de estratégia de produção. Variáveis controladas: TRG1 (esquerda) e TRG2 (direita). Perturbação: variável TAI com intensidade de +8%, com inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: maximizar a produção de GLP .....	93
Figura 4.23 Resultados obtidos do teste de mudança de estratégia de produção. Variáveis controladas: Severidade da Reação Catalítica (esquerda) e TRX (direita). Perturbação: degrau na variável TAI com intensidade de +8%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: maximizar a produção de GLP .....	93
Figura 4.24 Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização maximizar a produção de GLP ao invés de Nafta. Resposta à uma perturbação na variável TAI com intensidade de +8%, com inserção de ruído de 1,5% nas variáveis controladas .....	94
Figura 4.25 Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de otimização maximizar a produção de GLP. Resposta à uma perturbação na variável TAI de intensidade +8%, com inserção de ruído de 1,5% nas variáveis controladas .....	94
Figura 4.26 Resposta comparativa entre os resultados das Temperaturas de Saída das Fases Densas do Regenerador, primeiro e segundo estágios – TRG1 e TRG2. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992) .....	95
Figura 4.27 Resposta comparativa entre os resultados da Severidade da Reação Catalítica. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992) .....	96
Figura 4.28 Resposta comparativa entre os resultados da Temperatura de Saída do <i>Riser</i> – TRX. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992) .....	96
Figura 4.29 Resposta comparativa entre os resultados da Temperatura da Fase Diluída do Segundo Estágio do Regenerador – TD2. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992) .....	97

## LISTA DE TABELAS

Tabela 4.1 Exemplos de alguns resultados de arquiteturas de RNA obtidos para determinação dos parâmetros da rede: número de degraus, número de padrões de treinamento e precisão do gradiente .....	67
Tabela 4.2 Variáveis manipuladas, suas respectivas perturbações impostas, frequência de amostragem e intervalo de tempo entre cada degrau para os conjuntos de treinamento e validação das RNA, nas configurações 1 e 2 .....	70
Tabela 4.3 Variáveis manipuladas, suas respectivas perturbações impostas, frequência e tempo de amostragem para o conjunto de teste das redes neurais, nas configurações 1 e 2 .....	71
Tabela 4.4 Característica da rede neural que irá representar a unidade FCC como modelo interno do controle preditivo .....	71
Tabela 4.5 Valores obtidos de Pesos e <i>Bias</i> da Rede Neural com arquitetura 8x15x4, obtidos a partir de 1367 padrões de treinamento, considerando um valor de $5,261e-4$ no gradiente da função objetivo e amostragem de 6 em 6 minutos .....	72
Tabela 4.6 Dados referentes às condições operacionais do controle preditivo DMC utilizando um modelo de convolução (MORO,1992) .....	82

## NOMENCLATURA

### Lista de abreviaturas e siglas

AI	- <i>Artificial Intelligence</i>
ANN	- <i>Artificial Neural Networks</i>
BFGS	- <i>Broyden-Fletcher-Goldfarb-Shanno</i>
CO	- Monóxido de carbono
CO <sub>2</sub>	- Dióxido de Carbono
CSTR	- <i>Continuous Stirred Tank Reactor</i>
CTCV	- abertura da válvula de catalisador regenerado (abertura de válvula)
DDE	- <i>Differential Difference Equation</i>
DFP	- <i>Davidon-Fletcher-Powell</i>
DMC	- <i>Dynamic Matrix Control</i>
FCC	- <i>Fluid Catalytic Cracking</i>
FCCU	- <i>Fluid Catalytic Cracking Unit</i>
FINEP	- Financiadora de Estudos e Projetos
FLCs	- <i>Fuzzy Logic Controller</i>
GDR	- <i>Generalized Delta-Rule</i>
GLP	- Gás Liquefeito de Petróleo
GMC	- <i>Generic Model Control</i>
GPC	- <i>Generalized Predictive Control</i>
IA	- Inteligência Artificial
IAE	- <i>Integral Absolute Error</i>
IMC	- <i>Internal Model Control</i>
KCC	- constante de reação (experimental)
LCO	- <i>Light Cycle Oil</i>
LDMC	- <i>Linear Dynamic Matrix Control</i>
MAC	- <i>Model Algorithmic Control</i>
MBPC	- <i>Model Base Predictive Control</i>
MIMO	- <i>Multiple Input and Multiple Output</i>
MISO	- <i>Multiple Input and Single Output</i>
MPC	- <i>Model Predictive Control</i>

MPLs	- <i>Multilayer Perceptrons</i>
NARX	- <i>Non-linear Auto-Regressive eXogenous</i>
NMPC	- <i>Neural Model Predictive Control</i>
NNIMC	- <i>Neural Network Internal Model Control</i>
NO <sub>x</sub>	- Óxidos de Nitrogênio
PCA	- <i>Principal Component Analysis</i>
PI	- <i>Proportional Integral</i>
PID	- <i>Proportional Integral Derivative</i>
QDMC	- <i>Quadratic Dynamic Matrix Control</i>
RAI	- vazão de ar total para o Regenerador (Nm <sup>3</sup> /h)
RAI1	- vazão de ar para o primeiro estágio do regenerador (Nm <sup>3</sup> /h)
RAI2	- vazão de ar para o segundo estágio do regenerador (Nm <sup>3</sup> /h)
RECOPE	- Projeto de Redes Cooperativas de Pesquisa
RHC	- <i>Receding Horizon Control</i>
RNA	- Redes Neurais Artificiais
RTF	- vazão de alimentação do <i>Riser</i> (m <sup>3</sup> /h)
SETPDCV	- <i>setpoint</i> do diferencial de pressão entre o regenerador e o reator
SETSEV	- <i>setpoint</i> da variável severidade da reação catalítica
SETTRX	- <i>setpoint</i> da variável temperatura na saída do <i>Riser</i>
SEV	- severidade da reação catalítica
SISO	- <i>Single Input and Single Output</i>
SO <sub>x</sub>	- Óxidos de Enxofre
SQP	- <i>Successive Quadratic Programming</i>
SSQ	- <i>Sum of Square of residual</i>
TAI	- temperatura do ar para o regenerador (°C)
TD2	- temperatura de saída da fase diluída do segundo estágio do regenerador (°C)
TDG	- temperatura de saída da fase diluída geral do regenerador (°C)
TFP	- temperatura da alimentação do <i>Riser</i> (°C)
TRG1	- temperatura da fase densa do primeiro estágio de regeneração (°C)
TRG2	- temperatura da fase densa do segundo estágio de regeneração (°C)
TRX	- temperatura na saída do <i>Riser</i> (°C)

## Lista de Símbolos

### Símbolos latinos

$H$	- matriz Hessiana das derivadas segundas parciais da função objetivo em relação às variáveis independentes
$corr$	- correção do valor de $y$ predito para cada instante de predição
$d$	- representa o vetor distúrbio
$e$	- erro entre valor predito e valor desejado da variável $y$ no treinamento da rede
$E$	- função objetivo do treinamento da rede neural
$E_p$	- função erro de cada padrão
$exp$	- exponencial
$f$	- função de ativação de cada neurônio
$j$	- função objetivo
$k$	- índice: representa o instante atual
$m, n$	- parâmetro relacionado à ordem do modelo de identificação
$n$	- representação do neurônio
$N_c$	- horizonte de controle
$N_p$	- horizonte de predição
$p$	- índice: representa um padrão $p$ qualquer
$q$	- índice: representa variáveis controladas
$r$	- índice: representa variáveis manipuladas
$S$	- saída do neurônio
$sp$	- <i>setpoint</i> (trajetória de referência)
$t$	- saída do processo
$tanh$	- tangente hiperbólica
$u$	- valor de entrada de um processo (representa as variáveis manipuladas do processo)
$V_{max}$	- valor máximo assumido pela variável
$V_{min}$	- valor mínimo assumido pela variável
$V_{nor}$	- valor normalizado
$V_{real}$	- valor da variável nas unidades do processo

- $w$  - representação dos pesos das conexões
- $y$  - valor de saída de um processo (representa as variáveis controladas do processo)

#### Símbolos gregos

- $\alpha$  - pesos de igual importância nas variáveis controladas
- $\beta$  - filtro para definição das trajetórias de referência
- $\varepsilon$  - constante de momento (*momentum*) no método do gradiente conjugado
- $\eta$  - taxa de aprendizado no método do gradiente conjugado
- $\theta$  - *bias* ou *threshold*
- $\lambda$  - função auxiliar que representa a soma das entradas de um neurônio; pesos utilizados para penalizar variações excessivas da variável manipulada
- $\Delta$  - variação ou delta de uma unidade qualquer
- $\nabla$  - representa o gradiente de uma função

#### Símbolos especiais

- $\hat{\phantom{x}}$  - símbolo acima das variáveis representativo de variável predita
- $\underline{\phantom{x}}$  - símbolo abaixo das variáveis representativo de vetor

# CAPÍTULO I

## INTRODUÇÃO

### 1.1 Objetivos

A unidade de craqueamento catalítico em leito fluido (do inglês *Fluid Cracking Catalytic Unit – FCCU* ou simplesmente *FCC*) é uma unidade pertencente às refinarias de petróleo. Apresenta como objetivo principal o de transformar matéria prima de grande peso molecular em produtos mais leves que possuem alto valor agregado. Ela representa o maior processo catalítico do mundo e é fundamental não apenas para as refinarias, mas também para o cenário econômico mundial, em função da importância de seus produtos. Basicamente, esta unidade é composta por um reator e um regenerador, e por possuírem elevada interação entre suas variáveis de processo e em função da complexidade das cinéticas químicas envolvidas nas reações catalíticas, apresentam dificuldades dinâmicas e conseqüentemente dificuldades para operar e controlar. Frequentemente essas unidades são reguladas por meio de controladores PID padrões e também através de controle manual baseado no conhecimento de operadores das refinarias. A meta dessa unidade é maximizar a produção de Nafta (gasolina automotiva) ou de GLP (Gás Liquefeito de Petróleo), controlando a conversão e as variáveis mais representativas, frente às perturbações externas e variações na qualidade da carga.

Os processos químicos, na sua maioria, apresentam características fortemente não lineares, entretanto normalmente se utiliza um modelo linear no projeto do controlador devido às suas facilidades de implementação. A utilização desse modelo linear, juntamente com os controladores PID, apesar de sua versatilidade, pode ser satisfatória numa certa região operacional, mas não globalmente. O controle preditivo, por outro lado, apresenta a vantagem de permitir a incorporação de modelos não lineares em sua formulação de forma direta (LIMA & OLIVEIRA, 1997). Porém, um modelo não linear é difícil de ser representado, necessitando do bom conhecimento do processo, além de exigir procedimentos computacionais normalmente complexos principalmente no que se refere a sistemas multivariáveis, caracterizados como sistema de múltiplas entradas e múltiplas saídas (*MIMO – Multi Input Multi Output*), com elevada interação entre as variáveis do processo e com fortes restrições (LIMA & OLIVEIRA, 1997). A unidade de FCC

representa um processo com essas características, apresentando restrições de processo e condições de operação extremamente severas. O elevado grau de interação entre as variáveis envolvidas no processo de FCC torna esse controle bastante complexo para ser realizado utilizando a técnica do desacoplamento das variáveis, muito usada para sistemas MIMO em geral; nestes casos a utilização de um controle avançado multivariável se torna uma alternativa bastante aceitável. O controle preditivo com modelo (de sua denominação em inglês como é conhecida *Model Predictive Control – MPC*) se apresenta atualmente como o controle avançado de processo mais utilizado para este tipo de atuação, e o controle por matriz dinâmica, utilizando modelo de convolução (do inglês – *Dynamic Matrix Control – DMC*), representa o controle tradicional proposto para sistemas como os da unidade FCC, sendo sua técnica já bastante conhecida.

O algoritmo DMC desenvolvido para a unidade FCC, conforme descrito por MORO (1992) se baseia em representações numéricas da dinâmica do processo, descritas por um sistema de equações diferenciais lineares. O controle linear multivariável apresenta como vantagem a facilidade de compor o vetor resultante das perturbações simplesmente somando linearmente os efeitos de cada perturbação individual. Isto representa uma aproximação do modelo, uma vez que o sistema é inerentemente não linear, e esta propriedade não se aplica necessariamente a um sistema não linear. O controle LDMC (*Linear Dynamic Matrix Control*) existente na unidade FCC atua em dois módulos: um no nível estático, implementando as restrições do modelo; e outro no nível dinâmico, onde as ações de controle são calculadas a partir dos valores de referência (*setpoints*) fornecidos pelo nível estático. Podem ser observadas pelo menos duas desvantagens deste controle: a primeira seria a utilização de um controle linear (LDMC) para representar o processo altamente não linear; e a segunda seria a necessidade de se dividir o controle em dois módulos para permitir sua implementação, uma vez que utilizando o LDMC para manipular as restrições, realizar ações de controle e otimização em todas as previsões futuras, iria gerar uma matriz de programação linear muito grande, impossibilitando sua implementação *on-line*.

A criação de computadores digitais de baixo custo e alta velocidade de processamento possibilitou o uso de métodos matemáticos complexos e mais precisos, em substituição aos métodos simplificados, na implantação de controle avançado de processos.

Com o aperfeiçoamento destes computadores, uma área que se expande é a aplicação de Redes Neurais Artificiais (RNA) (em inglês *Artificial Neural Networks – ANN*), para otimização e controle de processos. A utilização de Redes Neurais Artificiais em controle de processo já está bastante difundida nos meios de pesquisa, sendo encontrados diversos estudos na literatura comparando suas bases matemáticas e algumas aplicações industriais de sucesso, conforme NARENDRA (1996). As RNA permitem que se simule um processo químico qualquer, sendo ele linear ou não linear, conhecendo-se um histórico operacional do processo ou apenas conhecendo-se os dados de entrada e as respostas correspondentes, mesmo que não se tenha certeza do mecanismo que rege este processo (NARENDRA & MUKHOPADHYAY, 1997). O método se fundamenta na Inteligência Artificial (IA) (do inglês *Artificial Intelligence – AI*).

A unidade de FCC, por ser extremamente complexa, faz com que qualquer tentativa de modelá-la matematicamente gere uma representação bastante aproximada. Entretanto, devido ao elevado valor agregado de seus produtos - pois representa o maior potencial de ganho econômico de todos os processos de refino de petróleo - torna compensador qualquer investimento na área de modelagem (KRISHNA & PARKIN, 1985). O controle preditivo que faz uso de Redes Neurais como modelo para representar a dinâmica do processo é denominado por alguns autores (ZHAN & ISHIDA, 1997) de controle por Modelo Interno (do inglês *Neural Network Internal Model Control – NNIMC* ou simplesmente *IMC*). A potencialidade desta ferramenta foi decisiva na escolha do método a ser aplicado neste trabalho. Até o momento não foi encontrado nenhum artigo na literatura envolvendo o controle de sistemas dessa complexidade, com características multivariáveis, utilizando as RNA como modelo do controlador o que de certa forma fornece um caráter inédito ao tema proposto.

Moro, em sua dissertação de mestrado, fazendo uso de um modelo da unidade FCC desenvolvido por KURIHARA (*apud* MORO, 1992), apresentou um estudo do estado estacionário, onde implementou uma estratégia de controle preditivo, usando DMC através de um modelo de convolução. Moro validou o modelo fenomenológico, obtido por princípios termodinâmicos e de conservação de massa e energia, com os dados da própria unidade industrial; a existência desse modelo fenomenológico motivou a realização deste estudo.

A proposta aqui é realizar a identificação do processo de FCC, utilizando o modelo fenomenológico desenvolvido por Moro, criando a partir desta identificação um modelo em redes neurais para simular o comportamento dinâmico das variáveis mais significativas deste processo. Posteriormente, desenvolver um controlador preditivo para esta unidade e usar as redes neurais como modelo do controlador. Para verificar seu desempenho, é previsto realizar alguns testes envolvendo perturbações nas variáveis do processo, assim como efetuar uma comparação entre os resultados do controlador DMC obtido da literatura MORO (1992), e os resultados do controlador proposto.

Recentemente, as pesquisas no Brasil envolvendo a área de petróleo foram descentralizadas em função da quebra do monopólio nessa área, tendo sido disponibilizadas para as diversas instituições de pesquisa do país. Dentro desta estratégia de descentralização foi criada uma rede de pesquisa denominada de projeto RECOPE/TACP (REdes COoperativas de PEsquisa/Técnicas Avançadas de Controle de Processos), financiada pela FINEP, integrando diversas instituições de ensino superior e centros de pesquisa do país, com objetivo de estudar e desenvolver métodos de controle de processos na área de petróleo. A unidade de FCC, modelo *Kellogg Orthoflow F* representa um dos temas escolhidos para fazer parte do projeto RECOPE, e este estudo é parte integrante deste projeto.

## **1.2 Estrutura do trabalho**

No CAPÍTULO II é feita uma Revisão Bibliográfica, onde são comentados os estudos encontrados na literatura que foram tomados como base para realização desta proposta, relacionados à unidade de FCC - item 2.1, e também à técnica de redes neurais - item 2.2, sendo incluídos um breve histórico e um resumo da técnica, dando ênfase em identificação e controle de processos; e no item 2.3 é apresentada a proposta da tese. No CAPÍTULO III sob o título Modelagem Matemática do Processo é apresentada uma breve descrição de processo de FCC - item 3.1, uma descrição da operação da unidade e o controle convencional normalmente utilizado, com objetivo de situar o leitor no tema abordado. O estudo da técnica de Redes Neurais, onde são inseridos o método de treinamento utilizado e a metodologia de identificação, é apresentado no item 3.2. A descrição do processo de identificação da FCC em redes neurais - item 3.3 e o controle preditivo proposto - item 3.4, finalizam o capítulo. No CAPÍTULO IV são apresentados os

Resultados obtidos, distribuídos em Identificação do modelo - item 4.1, e Controlador Preditivo em Redes Neurais - item 4.2. Neste item estão relatadas as dificuldades encontradas, os resultados dos testes de desempenho do modelo e as comparações efetuadas. No CAPÍTULO V são apresentadas as Conclusões e Sugestões para trabalhos futuros. Posteriormente, são apresentadas as Referências Bibliográficas citadas no presente estudo. Nos ANEXOS estão mostrados o Algoritmo de Treinamento via Retropropagação (*Backpropagation*), utilizado na identificação da rede (ANEXO A); o Cálculo dos Elementos de  $\nabla e(w)$  do método *Steepest Descent*, citado no treinamento da rede neural são apresentados no ANEXO B; o Algoritmo do Controle Preditivo utilizando Redes Neurais é mostrado no ANEXO C; o Modelo Dinâmico do Conversor, que foi utilizado como simulador da unidade industrial e também para obtenção dos dados de treinamento, está incluído no ANEXO D. o Algoritmo de Identificação do Processo em Redes Neurais Artificiais é apresentado no ANEXO E. Os artigos enviados para publicação e aceitos para apresentações em congressos, sendo publicados em Anais dos eventos, foram inseridos como APÊNDICES no presente estudo.

## CAPÍTULO II

### REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentados alguns estudos, obtidos da literatura, relacionados a unidade FCC, e as Redes Neurais Artificiais, os quais contribuíram para realização desta proposta.

#### 2.1 Unidade de Craqueamento Catalítico

A unidade de FCC é um dos processos mais importante em refinarias de petróleo devido à elevada capacidade de produção, rendimento de produtos e a importância deles. Um pequeno benefício neste processo é economicamente atraente. Além disso, as exigências dos regulamentos ambientais que restringem as emissões poluentes dessas unidades, como é o caso de CO, CO<sub>2</sub>, NO<sub>x</sub> e SO<sub>x</sub>, tornaram os seus controles muito importantes. Porém, as unidades de FCC representam processos fisicamente complexos e inúmeras são as dificuldades para operar e controlar. As seções do regenerador e do reator das unidades de FCC são altamente interativas e com dinâmica difícil. O processo, apesar de bastante estudado, é pouco conhecido principalmente por causa da complexidade das cinéticas químicas envolvidas. Na prática, as unidades de FCC são reguladas frequentemente por meio de controladores padrões PID (*Proportional Integral Derivative*) e também por ações de controle manual baseado no conhecimento dos operadores das refinarias (AGUILARA *et al.*, 1999).

Diversos estudos já foram realizados envolvendo a unidade de FCC, na tentativa de simular matematicamente a unidade, desenvolver equações que pudessem representar seus estados estacionários e avaliar o comportamento dinâmico de suas variáveis, utilizando equações dos princípios termodinâmicos e expressões cinéticas para a velocidade das reações, conforme se observa nos estudos de KURIHARA (1967), ISCOL (1970), LEE & KUGELMAN (1973), LEE & GROVES (1985), FALTSI-SARAVELOU *et al.* (1991), ARANDES & LASA (1992), BALCHEN *et al.* (1992), ZHENG (1994), KHANDALEKAR & RIGGS (1995), TVRZSKÁ DE GOUVÊA & ODLOAK (1998), WANG *et al.* (1999a,b), XU *et al.* (2001) e HODGSON *et al.* (2001).

São muitos os estudos que focalizam diretamente os problemas relacionados ao controle e otimização da unidade de FCC. ANSARI & TADÉ (2000) propuseram uma estratégia de otimização não linear com restrições aplicada à unidade de FCC. Neste caso o modelo dinâmico não linear do processo foi baseado em uma estrutura de unidade que utiliza um único estágio no regenerador - denominado de Modelo IV da AMCO; o qual foi usado para a análise da dinâmica da planta e para testes do sistema de controle não linear multivariável proposto. Foi desenvolvido um controlador preditivo com modelo interno (IMC), baseado na estratégia de Controle por Modelo Genérico (*Generic Model Control - GMC*), com inclusão de restrições dentro do próprio modelo do controlador. O modelo foi testado em uma aplicação em tempo real, sendo os resultados da simulação usados para atualização dos valores do sistema de controle (um algoritmo dinâmico de atualização de parâmetros), para prevenir os possíveis erros de modelagem. Em seu estudo foi dado maior importância em manter as variáveis dentro de seus limites de restrição do que em atingir um objetivo econômico. Ele mostrou que o ajuste do controlador multivariável não linear era muito mais fácil de ser executado do que o ajuste do controlador linear. Os resultados do controlador proposto concordaram favoravelmente aos resultados do DMC obtido do MATLAB® (utilizando uma estratégia de controle multivariável linear). Na presente proposta, é previsto utilizar um controle baseado no algoritmo MPC, similar ao desenvolvido por este estudo, utilizando como modelo interno do controlador (IMC) um modelo em redes neurais, ao invés do modelo fenomenológico.

ZANIN *et al.* (2000a) descrevem a implementação de uma nova estratégia de otimização não convencional em tempo real aplicada na maximização de produção de GLP (Gás Liquefeito do Petróleo) em um conversor FCC da Petrobrás na refinaria de São José dos Campos. Foram enfatizadas as dificuldades de otimização para os controladores existentes. Os testes efetuados foram descritos em detalhes. Eles mostraram que os benefícios da otimização não são restritos a fatores econômicos. A implementação da estratégia fornece meios de como mudar a forma de pensar dos operadores da unidade. A estratégia de otimização implementada mostrou ser capaz de manter o controle da planta até mesmo na ausência de algumas variáveis manipuladas e na presença de fortes perturbações. Além disso, foi mostrado que a estratégia de otimização pode direcionar o processo para novos pontos operacionais. Em outro estudo, ZANIN *et al.* (2000b), apresentaram algumas estratégias de otimização na unidade de FCC modelo *Kellog*

*Orthoflow F*, de forma a manter o controle avançado do processo em condições ótimas mesmo quando a estratégia proposta para unidade for alterada, ou seja, o otimizador atua em tempo real no controle avançado em qualquer estratégia de produção. Foi usado um modelo linear para predição das variáveis de saída do controlador. Foi proposto agilizar a estabilização da unidade mesmo na presença de fortes perturbações evitando as situações de desvio do estado estacionário (conhecido como *off-sets*). Na presente proposta é previsto utilizar o modelo *Kellog Orthoflow F* da FCC para obtenção dos dados de treinamento das redes neurais, desenvolver estratégias de otimização do controle além de testar o desempenho do controlador simulando a ausência de uma das variáveis manipuladas.

PRANATYASTO & QIN (2000) utilizaram um processo de Diagnose de Falhas no controle da unidade FCC da AMCO Modelo IV. Aplicaram um modelo de Análise do Componente Principal (*Principal Component Analysis - PCA*) para detectar e identificar falhas em sensores de medida. Alertaram que as falhas de sensores podem ser devido a ruído randômico, mau funcionamento ou descalibração de instrumento, e afirmaram que o controle pode ser ineficiente, se antes de sua ação não for feita uma verificação no sinal do instrumento, na tentativa de detectar erros grosseiros que possam influenciar nos resultados do controle. O método se baseia na simulação da perturbação no processo comparando o desempenho com e sem a validação dos dados. Concluíram que o controlador linear QDMC (*Quadratic Dynamic Matrix Control*) com validação de dados apresenta desempenho superior ao mesmo controlador sem validação. No presente estudo, acredita-se que o modelo proposto em RNA, por apresentar robustez e ser menos afetado com a presença de sinais ruidosos deverá apresentar bom desempenho mesmo em tais condições adversas, porém, será criada uma rotina desenvolvida em fontes de códigos computacionais em linguagem Fortran para gerar ruídos na etapa de identificação do modelo e também na etapa do controle preditivo e assim confirmar seu bom desempenho nessas condições.

GÁLVEZ & SOUZA (2000) apresentaram um projeto de controlador multivariável baseado no domínio de frequência, para a unidade FCC modelo *Kellog Orthoflow F*, utilizando o modelo matemático desenvolvido por MORO & ODLOAK (*apud* GÁLVEZ & SOUZA, 2000) como “unidade industrial”. Tendo realizado o desacoplamento das variáveis do controlador, foi discutida a flexibilidade do controle SISO neste controle desacoplado. Foi usado o controlador MPC/DMC, com o modelo

representado por um sistema MIMO 2X2. Observa-se, entretanto, que o modelo utilizado foi simplificado, pois originalmente deveria ser representado, no mínimo, por um sistema MIMO 4X4. No presente estudo, o mesmo modelo fenomenológico verificado por MORO & ODLOAK (1995), foi utilizado. O sistema MIMO proposto por GÁLVEZ & SOUZA (2000) será substituído por um modelo em RNA, não estando prevista nenhuma simplificação no modelo, apesar de ser esperado elevado grau de complexidade nessa simulação.

MORO (1992) apresentou como tema de mestrado o desenvolvimento de um controlador preditivo multivariável para unidade de FCC. O modelo do controlador adotado foi baseado no modelo fenomenológico de 10 *lumps* (grupos de componentes), desenvolvido por KURIHARA (*apud* MORO, 1992). Tendo em vista a utilização desse mesmo modelo como modelo fenomenológico para identificação em RNA, este estudo será descrito em mais detalhes a seguir.

O modelo desenvolvido por KURIHARA (1967) foi fundamentado em um sistema envolvendo o craqueamento no *Riser* e dois estágios de regeneração, com queima parcial do CO. As informações utilizadas na modelagem foram obtidas a partir de princípios de conservação e termodinâmicos na unidade de Craqueamento Catalítico. Estes princípios foram utilizados para simular a unidade industrial e as equações resultantes estão incluídas no ANEXO D do presente estudo.

Para a validação do modelo Moro realizou vários testes na unidade industrial e no modelo fenomenológico, comparando seus resultados. Estes testes constaram de aplicação de uma variação degrau a cada uma das variáveis manipuladas individualmente, mantendo as demais variáveis nos seus estados estacionários observando as respostas nas variáveis mais importantes, considerando o sistema aberto. O mesmo procedimento foi aplicado na unidade industrial obtendo essas respostas experimentalmente, sendo então feita uma comparação entre os resultados. Todos os testes apresentaram limitações na amplitude dos degraus devido a restrições de segurança e operacionais, sendo considerado como limite máximo um degrau de 1% nas variáveis manipuladas, tendo em vista que a operação da unidade não permitia degraus excessivos nessas variáveis e também devido à instabilidade operacional oriunda da operação de alguns controles em manual. Mesmo considerando a

imprecisão dos dados coletados industrialmente, e a limitação descrita acima, o modelo foi considerado satisfatório pelo autor.

O controle foi desenvolvido a partir do LDMC (*Linear Dynamic Matrix Control*), dividindo-o em duas partes: uma estática, onde são tratadas as restrições de processo; e outra dinâmica, onde são calculadas as ações de controle utilizando os valores de referência fornecidos pelo modelo no nível estático. Esta estratégia visou reduzir o esforço computacional exigido pelo sistema, no cálculo do modelo fenomenológico. Após validação do modelo, foi feita a aplicação do controlador proposto ao controle digital convencional da unidade. Para isto foram escolhidas as seguintes variáveis do processo como controladas: - temperatura de saída do reator, que representa bem as variações do processo; - severidade da reação catalítica, que representa de certa forma a conversão; e, - temperaturas do regenerador, fases densas do primeiro e segundo estágios. As variáveis escolhidas como manipuladas foram: - vazão de ar para o regenerador; - abertura da válvula de catalisador regenerado; - vazão de carga; e - temperatura da carga.

O primeiro teste do controlador consistiu de maximização da severidade; e o segundo teste de maximização da carga. Visando verificar a atuação do controlador frente a perturbações não medidas, foi aplicado um degrau no valor de referência do controlador de pressão diferencial reator/regenerador. Em todos os testes efetuados a atuação do controlador se mostrou eficiente. Isto levou o autor a concluir que o controle proposto era considerado adequado para implementação *on-line*. No presente estudo é proposto realizar a identificação do modelo de FCC através da simulação do sistema em malha aberta, utilizando o modelo matemático desenvolvido por Moro. Devido às restrições inerentes ao próprio modelo e às limitações operacionais descritas em sua dissertação, serão tomadas precauções para restringir a amplitude das variações em todas as variáveis controladas e associadas do processo. Posteriormente, no desenvolvimento do controlador preditivo, esse modelo fenomenológico será usado para simular a operação da unidade FCC.

A seguir, são citados ainda alguns estudos encontrados na literatura, referentes à simulação e/ou controle nas unidades de FCC, que além de confirmar o elevado interesse em pesquisa nessa área, a situa como uma área que, “apesar de bastante estudada, é pouco conhecida” (AGUILARA *et al.*, 1999), e por isto ainda apresenta muito a ser desenvolvido.

GROSDIDIER *et al.* (1993) visaram incluir as restrições inerentes ao processo dentro da malha de controle, utilizando um controlador MPC tipo IDCOM-M, na unidade FCC pertencente a *Neste Oy's Porvoo refinery* (projeto TEXACO<sup>®</sup>), sem sacrificar muito o tempo de processamento.

KHANDALEKAR & RIGGS (1995) propuseram um simulador dinâmico para a unidade de FCC, modelo IV da AMCO, desenvolvido usando modelos matemáticos. O conjunto de equações diferenciais resultantes deste modelo foi resolvido usando o método de Runge-Kutta de quarta ordem. O controle proposto foi baseado no tipo *Generic Model Control* (GMC).

MORO & ODLOAK (1995) utilizaram o modelo desenvolvido por MORO (1992), e conseguiram implementar degraus maiores que 1% nas variáveis manipuladas. Eles constataram que o modelo fenomenológico existente, desenvolvido para unidade de FCC, representa bem a dinâmica da unidade industrial, mesmo para degraus maiores que 1%.

KALRA & GEORGAKIS (1996) analisaram a influência das características operacionais do reator de FCC (Modelo IV da AMCO), utilizando MPC linear no controle do processo não linear, para diferentes condições de operação.

GOH *et al.* (1997) utilizam um modelo linear robusto para controle multivariável do processo do FCC, que foi considerado não linear, utilizando modelo baseado em controle preditivo por matriz dinâmica (DMC).

YANG *et al.* (1998) propuseram uma ação de controle hierárquica multi-objetiva, que pudesse, ao mesmo tempo, realizar o controle e também as restrições do processo de uma unidade de FCC. Um controle do tipo *Model Base Predictive Control* (MBPC), com inclusão de restrições de processo na formulação das leis de controle, foi proposto e desenvolvido, obedecendo a um critério de prioridades previamente estabelecido, de forma a não sobrecarregar computacionalmente o sistema.

AGUILARA *et al.* (1999), utilizaram um projeto de controle regulatório para estabilização das temperaturas do reator e do regenerador de uma unidade de FCC, utilizando o modelo de LEE & GROVES (*apud* AGUILARA *et al.*, 1999), criado a partir do modelo de 3 *lumps*. A estrutura do controlador proposta foi semelhante a um

compensador Proporcional duplo Integral ( $PI^2$ ), que de acordo com os autores, apresenta maior robustez do que o controle PI tradicional.

ANTONIADES & CHRISTOFIDES (1999) propuseram uma metodologia para a síntese de controladores não lineares de realimentação para sistemas com uma única entrada e única saída (SISO - *Single Input and Single Output*) não linear denominada *Differential Difference Equation (DDE)* que inclui retardo de tempo no atuador de controle e no sensor de medida, sendo aplicada com sucesso em uma unidade de FCC.

NIEDERBERGER *et al.* (2000) apresentaram um software de simulação/otimização de processo de unidades de FCC pertencente à Petrobrás, denominado de *SIMCRAQ<sup>OT</sup>* (um simulador estático destinado à avaliação, otimização e projeto de conversores de unidades de FCC; desenvolvido pelo Programa de Desenvolvimento de Tecnologia e Estratégica de Refino – PROTER, através do Programa FCC – Petrobrás, para a conversão de resíduos). Este software, de acordo com os autores, pode ser usado em todas as unidades de produção, independente do modelo existente, permitindo simulações, ajuste de parâmetros e otimização onde se procura condições operacionais que garantam máxima rentabilidade. O modelo incorpora as melhorias no processo de FCC realizadas ao longo de anos na companhia. Este pacote apresenta como principal característica a facilidade de uso devido à interface gráfica do software, apresentando fácil sintonia e se adaptando às diversas geometrias de reator/regenerador, capacidades e qualidade de carga, relatam seus autores.

Poucos artigos foram encontrados na literatura até a presente data, relacionando FCC e RNA ou rede *Fuzzy*, merecendo destaque:

RUIZ & SONNET (2000) descrevem a aplicação de um pacote comercial (*NeurOn-Line Studio, Gensym Corporation, Cambridge, Massachusetts, USA*), desenvolvido utilizando estruturas em RNA para análise, otimização e como redutores de modelo. No mesmo pacote, são previstos a configuração do modelo, treinamento, validação e teste. Para maximização de produtividade, podem ser tomadas decisões assistidas ou automáticas, podendo ser incorporadas restrições de processo. O pacote foi testado na unidade FCC pertencente à unidade *REPSOL YPF* da refinaria de *La Plata, Buenos Aires, Argentina*, na área de controle de qualidade, desenvolvendo um sistema de inferenciação em linha do ponto de destilação 90% de Nafta, para criar dessa forma um modelo reduzido

em redes neurais. O modelo criado mostrou boa predição do ponto de destilação 90% de Nafta.

SARMA & RENGASWAMY (2000) desenvolveram um controlador com base na rede *Fuzzy (Fuzzy Logic Controller – FLCs)* para ser utilizado numa unidade com característica não linear e com fortes interações entre suas variáveis de operação. O FLCs foi considerado adequado para ser utilizado com um desacoplador linear (*Static Linear Decoupler – SLD*), agindo como um controlador multivariável “descentralizado”, denominado GS-FLC/SLD multivariável (*General Sigmoidal Gain-Scheduled Fuzzy Logic Controller*). Esta técnica de controle foi aplicada em uma unidade de FCC, modelada como um sistema com dinâmica de ordem 3, e o sistema multivariável GS-FLC/SLD demonstrou um bom desempenho de controle servindo como servo/regulatório e apresentando robustez.

WANG *et al.* (1999a) propuseram um estudo usando funções *wavelet* e redes neurais para identificação e diagnóstico de processo. Em outro artigo, WANG *et al.* (1999b), testaram o sistema proposto anteriormente numa unidade de FCC.

SANTOS *et al.* (2000a) reportam o uso de redes neurais na identificação de processo da FCC, considerando dois modelos distintos, um mais complexo, desenvolvido por Kurihara, e outro mais simples, desenvolvido por Lee & Kugelman. Neste último modelo foi possível um estudo detalhado, com cálculo do ponto de operação ótimo, dentro dos padrões de estabilidade, utilizando-se um programa computacional, (AUTO/97). Este programa (AUTO/97), disponível em fontes de códigos computacionais em linguagem Fortran, é utilizado para obtenção dos diagramas de bifurcação onde localiza as regiões de operação estáveis. Neste estudo eles se limitaram a sistema SISO para ambos os modelos. Foi proposto ainda o controle do processo do FCC baseado no controle preditivo, utilizando o modelo desenvolvido na identificação, sendo aplicado apenas no modelo de Lee & Kugelman. Os resultados mostraram que as RNA capturaram o comportamento não linear do processo com relativamente poucos neurônios. No presente estudo é previsto utilizar um processo de identificação, baseado em RNA, semelhante ao descrito no estudo de Santos, considerando, entretanto, o sistema MIMO que apresenta características bem mais complexas. A rotina de controle proposta também é semelhante à rotina desenvolvida naquele estudo.

Conforme pode ser observado do exposto acima, o problema de controle da unidade FCC tem sido amplamente abordado por várias metodologias. Uma identificação desse processo multivariável em redes neurais, devido à complexidade da rede resultante e principalmente à pesada carga computacional exigida pelo método de treinamento da rede neural, ainda não tinha sido realizada. Por outro lado, o processo de FCC representa um desafio onde benefícios significativos para indústria de processo e para teoria de controle poderiam ser alcançados, e a identificação desse processo baseada em redes neurais pode fornecer ao projetista desta unidade um melhor entendimento da dinâmica do processo podendo ser útil como um modelo interno para o Controle Preditivo. O Modelo de Controle Preditivo é baseado em um índice de desempenho global e parametrização das variáveis de controle em um modelo não linear, com inclusão de restrições, conforme relatado em BALCHEN *et al.* (1992), GROSDIDIER *et al.* (1993) e ALI & ELNASHAIE (1997). O modelo desenvolvido em redes neurais, resultante de um processo de identificação, por ser mais robusto do que aqueles desenvolvidos por métodos tradicionais, onde se utilizam modelos fenomenológicos, é menos influenciado pela presença de ruídos, podendo ser adequado seu uso em sistemas ruidosos (NARENDRA, 1996).

## 2.2 Redes Neurais Artificiais

### 2.2.1 Histórico

As primeiras pesquisas realizadas relacionando “sinais de perspicácia” associada à atividade cerebral apontam para o século XVIII em um texto *Psychology (Briefer Course)*, datado de 1890 de William James (*apud* NELSON & ILLINGWORTH, 1991; SIMPSON, 1990). Entretanto, apenas em 1943, em trabalho publicado por McCulloch e Pitts, é apresentado um modelo em redes neurais utilizando circuitos elétricos (PRETT & GARCIA, 1988; SIMPSON, 1990; NELSON & ILLINGWORTH, 1991). Em 1949, Donald Hebb lançou o livro “*The Organization of Behavior*”; o método de treinamento descrito por ele, *Hebb’s Learning Rule*, ainda hoje é bastante utilizado. Na década de 50 implementou-se o estudo da aprendizagem em redes neurais, sendo que no fim da década foram criados alguns projetos de aprendizagem, entre eles o denominado *Perceptron* de FRANK ROSENBLATT (*apud* NELSON & ILLINGWORTH, 1991); BERNARD WIDROW and MARCIAN HOFF (*apud* NELSON & ILLINGWORTH, 1991) desenvolveram o modelo MADALINE (*Multiple ADaptive LINear Elements*), que foi a

primeira aplicação de redes neurais em um processo real – a criação de filtros adaptativos para eliminar ecos em linha telefônica. De acordo com o método de aprendizagem proposto por Rosenblatt, para *perceptrons* com duas camadas – uma de entrada outra de saída, os pesos eram ajustados conforme a diferença entre os resultados obtidos computacionalmente e os resultados esperados (SIMPSON, 1990; NELSON & ILLINGWORTH, 1991). Na década de 60 existiam duas linhas de estudo divergentes entre si, ambas defendendo o interesse em propor uma modelagem para compor a Inteligência Artificial - IA; uma que foi defendida por Rosenblatt – autor de “Princípios de Neurodinâmica” – sugeriu o *perceptron* como base para a modelagem do cérebro e a IA; e outra defendida por Minsky M. e Papert S. – apoiavam a teoria de um processamento simbólico serial para a IA (SIMPSON, 1990). Como resultado destas análises e com o sucesso dos processos simbólicos, o estudo das redes neurais ficou um pouco esquecido por longo período. Na década de 70, os estudos aplicando redes neurais ficaram restritos a alguns pesquisadores no Japão, Europa e União Soviética. Somente na década de 80, com o surgimento de computadores digitais mais rápido e com a descoberta de métodos eficientes de treinamento, auxiliado pela influência do físico John Hopfield que atraiu seguidores para sua área de pesquisa, é que os estudos na área de redes neurais prosseguiram com certo entusiasmo. Hopfield propôs uma arquitetura de redes neurais que leva hoje seu nome (SIMPSON, 1990; DE SOUZA JR., 1993; HAYKIN, 1994). Nos dias de hoje, dezenas de outras arquiteturas de rede neural são conhecidas, entre elas: *Adaline*; *Perceptron*; *Counterpropagation*; *Neocognitron*; Mapas Auto-Organizáveis; Memórias Associativas Bidirecionais; *Wave-nets*; *Backpropagation*; Teoria da Ressonância Adaptativa, dentre outras (DE SOUZA JR., 1993). Alguns *softwares*, que utilizam esta técnica também estão disponíveis nos diversos pacotes de métodos matemáticos, podendo citar entre eles o MATLAB<sup>®</sup>; sendo já bastante conhecida a utilização de suas rotinas em redes neurais e redes *Fuzzy* para solução de sistemas lineares e não lineares. As aplicações das RNA nos dias atuais atingem diversos campos do conhecimento, mas é na área das ciências exatas que elas se apresentam em maior peso.

### **2.2.2 As Redes Neurais Artificiais**

Diversos estudos bem sucedidos encontrados na literatura comprovam a eficácia das RNA aplicadas às várias categorias de processos, como observado nos estudos relativos a processos químicos e bioquímicos (WANG *et al.*, 1998; DI MASSIMO *et al.*, 1992), e

também aos aplicados a processos contínuos (HOSKINS & HIMMELBLAU, 1992; WANG *et al.*, 1998; ALVES & NASCIMENTO, 2001) e em batelada (FENG & JIN, 1993; DONG *et al.*, 1996; FILETI & PEREIRA, 1997; KROTHAPALLY & PALANKI, 1997, GREAVES *et al.*, 2001). Na área de simulação, assim como em controle de processos, utilizando a linha adaptativa ou preditiva, também são encontrados estudos envolvendo as RNA e/ou redes de lógica *Fuzzy*, destacando-se os estudos de NASCIMENTO JR. (1994), NARENDRA (1996), NARENDRA & MUKHOPADHYAY (1997), FILETI & PEREIRA (1997), PEREIRA FILHO (1999), ZHAO *et al.* (2000), FILETI *et al.* (2000) e SARMA & RENGASWAMY (2000). Alguns destes artigos em RNA abordam análise, identificação e otimização de processos como observado em POLLARD *et al.* (1992), SAVKOVIC'-STEVANOVIC' (1994), NIKRAVESH *et al.* (1996), e outros as utilizam em diagnose de falhas (KAVURI & VENKATASUBRAMANIAN, 1992), ou em inferenciação *on-line* PEDROSA *et al.* (2001).

Especificamente na área de controle, diversos autores centralizaram seus estudos em metodologias alternativas para otimizar a atuação de controladores em processos, como é o caso de BHAT & McAVOY (1990), HERNÁNDEZ & ARKUN (1992), ZHAN & ISHIDA (1992), YAMADA & YABUTA (1992), LEVIN & NARENDRA (1993), LEVIN & NARENDRA (1996), KIM *et al.* (1997), NARENDRA & MUKHOPADHYAY (1997) e WANG *et al.* (1998). Analisando apenas o aspecto matemático do método de redes neurais, autores como JOSEPH *et al.* (1992) e HOLCOMB & MORARI (1992), se preocuparam em realizar comparações entre as redes neurais e os métodos clássicos, como métodos lineares e métodos estatísticos, visando comprovar o bom desempenho dessa técnica. Outros propuseram ainda novas arquiteturas e/ou metodologias de treinamento para as redes neurais, visando principalmente reduzir o tempo de processamento de computador (denominado de tempo de CPU), conforme se pode constatar nos trabalhos de BHAT & McAVOY (1992), YANG *et al.* (1994), ROBITAILLE *et al.* (1996), SALOMON & HEMMEN (1996), ZAINUDDIN & EVANS (1997), KROTHAPALLY & PALANKI (1997), KAMARTHI & PITTNER (1999) e WANG & ZHU (2000).

STEPHANOPOULOS & HAN (1996) apresentaram um apanhado do estado da arte numa revisão dos estudos da literatura que utilizaram sistemas baseados em rotinas computacionais, classificados como “Sistemas Inteligentes” nas diversas áreas da

Engenharia de Processos (comentaram entretanto que o termo “inteligente” foi empregado erroneamente, e que alguns autores preferiram denominá-los de “conhecimento”). Na área de controladores “inteligentes”, os autores citaram que sistemas de controle baseados em lógicas *Fuzzy* e em redes neurais são muito eficazes como aproximadores de função em sistemas não lineares; isto permitiu uma expansão sem precedentes de artigos publicados em algumas áreas, como em retificação de dados, avaliação e otimização de processos operacionais, diagnose de falhas, estimação de estados, identificação de processos e reconhecimento de padrões. Acrescentaram ainda que na caracterização das RNA é necessário definir sua topologia e a função de transferência nos nós da rede; para determinar sua estrutura deve ser especificado o número de camadas, o número de nós por camada, o grau de conectividade, o “caminho” e o tipo das conexões. Entretanto, precisa ainda ser avaliado o conjunto de dados a ser apresentado à rede como padrões e qual o critério de aproximação a ser adotado no modelo. Em controle preditivo, eles citam a aplicação de RNA como modelo não linear de processo, o qual pode ser usado para prever a resposta futura do mesmo em aplicações de controle e monitoramento de processos. Este estudo foi bastante útil para avaliar a tendência dos estudos em redes neurais, auxiliando também na compreensão da sua estrutura e definição das variáveis que interferem diretamente nas RNA, além de fornecer uma vasta fonte de referências.

NARENDRA (1996), em um breve resumo, relata o avanço do uso de RNA nas diversas áreas, sua aplicação em controle de processos não lineares, enfocando também algumas aplicações de sucesso na indústria. Cita ainda que, o fato de as redes neurais serem mais tolerantes a falhas, menos sensíveis à ruído inerente ao sistema, apresentando robustez, e mais facilmente implementado do que as aproximações por métodos convencionais utilizando funções polinomiais, séries trigonométricas, métodos estatísticos ou outros, é que faz com que elas sejam mais recomendadas em controle de processos do que os outros métodos.

Um sistema com dinâmica não linear é representado em seu estudo pela equação de estado  $\Sigma$ :

$$\begin{aligned} \sum : \quad & x(k+1) = f[x(k), u(k)], \quad f(0,0) = 0 \\ & y(k) = h[x(k)], \quad h(0) = 0 \end{aligned} \quad (2.1)$$

onde  $u(k)$ ,  $y(k) \in \mathfrak{R}^m$  e  $x(k) \in \mathfrak{R}^n$  representam a entrada, saída e vetor de estado, respectivamente, no tempo  $k$  e as funções  $f$  e  $h$  são assumidas serem suaves, isto é, possuem derivada contínua em toda a extensão.

O objetivo é determinar uma condição sob a qual um vetor de entrada  $u(k)$  pode ser obtido tal que a saída do sistema assuma determinado comportamento. Os expoentes  $m$  e  $n$  determinam o sistema, ou seja, se  $m = n = 1$  então o sistema apresenta única entrada e única saída (SISO), caso  $m = 1$  e  $n > 1$  tem-se um sistema de única entrada e múltiplas saídas (SIMO), caso  $m > 1$  e  $n > 1$  o sistema apresenta múltiplas entradas e múltiplas saídas (MIMO). O primeiro passo para este tipo de controle é a identificação do mesmo utilizando os sinais disponíveis. Esta identificação consiste em selecionar um modelo paramétrico adequado e ajustar seus parâmetros visando otimizar o critério de desempenho baseado no erro entre a saída da planta e a saída do modelo. Se a rede neural, representada por funções discretas  $N_f$  e  $N_h$  é então usada para aproximar as funções  $f$  e  $h$ , o modelo assume a forma:

$$\begin{aligned} \hat{x}(k+1) &= N_f[x(k), u(k)] \\ \hat{y}(k) &= N_h[x(k)] \end{aligned} \quad (2.2)$$

onde  $N_f$  e  $N_h$  são treinados por um método da literatura independentemente e seus parâmetros são ajustados de forma a minimizar as diferenças  $(x(k) - \hat{x}(k))$  e  $(y(k) - \hat{y}(k))$ , respectivamente. Como o sistema pode se tornar instável durante o treinamento *on-line*, todo treinamento num problema prático é levado usando um simulador *off-line*. Uma área onde o estudo de redes neurais tem se mostrado bastante atrativo é aquela onde o controle é baseado em dados de entrada e saída apenas. Como na maioria dos casos práticos o sistema a ser controlado apresenta múltiplas entradas e saídas, a eficácia da rede neural como controlador irá depender da aplicabilidade da metodologia normalmente

usada em controle multivariável. A dificuldade está justamente na interdependência normalmente observada entre as diversas entradas e saídas. Em caso de sistema tipicamente multivariável, com característica não linear, cujos parâmetros são desconhecidos, tem-se então um problema de controle adaptativo multivariável não linear. E é justamente aí que é mostrada a potencialidade das redes neurais. Outra área de interesse em pesquisa é o controle adaptativo por múltiplos modelos. Neste caso os controladores são desacoplados. O presente estudo está baseado em controle multivariável de um sistema MIMO, com  $m > 1$  e  $n > 1$ , usando dados de entrada e saída apenas. Devido ao elevado grau de interdependência das variáveis de processo da unidade FCC, o desacoplamento destas variáveis assumiria dimensões elevadas, com resultados possivelmente duvidosos. Desta forma, optou-se por não desacoplar o modelo do controlador.

SAVKOVIC'-STEVANOVIC' (1994) apresentou um estudo com objetivo de avaliar a aplicabilidade de redes neurais para análise de dados industriais. Foi apresentada uma arquitetura para rede neural constituída de três camadas distintas (*Input, Hidden and Output – IxHxO*), as quais foram classificadas como: as camadas de entrada (*I*), camada de percepção; interna ou escondida (*H*), camada conceitual; e camada de saída (*O*), camada de ação. A unidade de entrada (*I*) foi constituída de fatos ou condições de estado, a unidade escondida (*H*) situada entre as unidades de entrada e de saída foi responsável pela transformação dos dados de entrada em resultados de saída, e a unidade de saída (*O*) correspondeu aos resultados numéricos que foram comparados com os resultados esperados e decidir qual ação a ser tomada. Foram utilizadas funções de ativação do tipo *sigmoidal* e o treinamento da rede foi realizado através do procedimento de retropropagação. Aqui foi adotada a configuração totalmente por alimentação direta (do inglês *feedforward*) que é a configuração mais popular para este tipo de rede; o termo “totalmente” apresenta aqui o significado de que os neurônios de uma camada estão conectados apenas aos neurônios da camada seguinte, não havendo nenhuma ligação de retorno.

O treinamento da rede teve como meta atingir o mínimo erro, definido como a diferença entre a saída obtida do cálculo pela rede e o valor desejado para saída. Nesta etapa foram usados o algoritmo *Powell*, o método (*Sum of Square of residual – SSQ*), e o algoritmo da regra delta generalizada (*Generalized Delta-Rule – GDR*), para calcular os pesos da rede os quais minimizassem a função objetivo. No modo de treinamento foi

fornecido um conjunto de exemplos de treinamento consistindo de um par de vetores de entrada/saída. No processo de treinamento, a rede foi inicializada com um pequeno peso randômico em cada nó. Com o objetivo de avaliar o treinamento da rede neural no processo de classificação e otimização, dois casos foram investigados. O primeiro caso consistiu em uma coluna de destilação e separador líquido-líquido de um azeótropo heterogêneo. O segundo caso foi o processo de destilação azeotrópica de acetato de butila, álcool butílico e água, interconectado com a coluna de destilação industrial. Em ambos os casos estudados vários modelos de redes neurais foram explorados para encontrar a arquitetura que fornecesse o menor erro durante o treinamento.

Através desta investigação foi concluído pelo autor que as redes neurais têm um potencial a ser desenvolvido dentro da ferramenta de predição, e suas aplicações permitem que se façam a estimação dos parâmetros de processo para melhorar sua produtividade. O resultado do treinamento obtido pelo algoritmo GDR é comparável ao resultado obtido com o método *Powell* mesmo usando diferentes arquiteturas de redes. Seus resultados mostraram também a aplicabilidade das estruturas em redes neurais com e sem camada escondida, concluindo também que adicionando uma camada escondida aumenta-se o desempenho da rede, mas aumenta também o tempo computacional. Foi mostrado ainda o efeito positivo da combinação de redes neurais em módulos. A condição ótima de operação foi experimentalmente verificada na planta. No presente estudo, serão utilizadas RNA apresentando mesmo modelo de arquitetura mostrado acima, composto de três camadas com configuração *feedforward* com a função *sigmoidal* como função de ativação.

WANG *et al.* (1998) apresentaram uma estratégia de controle preditivo onde um processo não linear é modelado usando RNA. Foi proposto dividir o controle em duas partes, uma denominada de modelagem do processo não linear usando redes neurais e outra representando a técnica do controle preditivo. Seus estudos se limitaram ao caso de otimização onde apenas uma ação de controle é envolvida, obviamente a complexidade do problema aumenta quando o número de variáveis cresce. O caso estudado foi o controle de pH em um reator CSTR, onde existiam duas correntes de entrada: hidróxido de sódio e ácido acético. O fluxo de ácido foi fixado como constante –  $F_1$ , variando apenas a corrente de soda –  $F_2$  (como variável manipulada), o pH era a variável controlada. Aqui, a dificuldade observada era devido a grande variação na dinâmica do processo. Para este

sistema quatro entradas foram consideradas apropriadas, dois valores de pH ( $pH(t)$  e  $pH(t-1)$ ) e dois valores de vazão de soda ( $F_2(t)$  e  $F_2(t-1)$ ). Na saída, apenas um neurônio ( $pH(t+1)$ ), e na camada escondida foram escolhidos 10 neurônios. Foi observado que quando o número de nós na camada escondida é relativamente pequeno, o processo produz oscilações indesejáveis na região de viragem do pH mesmo que a performance tenha sido boa na fase de treinamento. Visando contornar este problema uma tentativa seria aumentar o número de nós na camada de entrada, acrescentando  $pH(t-2)$  e  $f_2(t-2)$  mas isto poderia levar a resultados errôneos pois aí o número de nós existentes na camada escondida já não seria capaz de treinar a rede adequadamente. Foi concluído que a escolha do número de nós de entrada deve ser baseada na análise do processo específico, e que um aumento excessivo não necessariamente aumenta o desempenho do sistema, podendo causar um problema de convergência e um aumento desnecessário da complexidade e da sobrecarga computacional. No presente estudo uma análise semelhante será adotada na escolha do número de elementos na camada de entrada, tomando-se o cuidado para não haver perda de generalidade do modelo em redes neurais e também não causar sobrecarga computacional, uma vez que a estratégia de controle proposta prevê atuação em mais de uma variável ao mesmo tempo.

ZHAN & ISHIDA (1997) apresentaram um modelo multipasso para o controle preditivo com modelo em um sistema com uma única entrada e única saída (SISO) não linear. A proposta apresentada foi utilizar controle preditivo utilizando redes neurais para simulação do modelo (*Neural Model Predictive Control – NMPC*). O objetivo básico foi selecionar um conjunto de ações de controle futuros que minimizassem uma função objetivo baseado na técnica de modelagem preditiva, sujeito a restrições de processo. A função a ser minimizada foi assim representada,

$$\min_{u(k), \dots, u(k+M-1)} \sum_{j=1}^N [y_{pred}(k+j) - y_{sp}(k+j)]^2, \quad (2.3)$$

sujeito às seguintes restrições:

$$\begin{aligned}
y_{\min} &\leq y_{pred}(k+j) \leq y_{\max} \quad (j=1, \dots, N) \\
u_{\min} &\leq u(k+i) \leq u_{\max} \quad (i=0, 1, \dots, M-1) \\
|u(k+i) - u(k+i-1)| &\leq \Delta u_{\max} \quad (i=0, 1, \dots, M-1),
\end{aligned}$$

onde  $N$  e  $M$  são os horizontes de predição e controle respectivamente.

Como o horizonte de predição é maior do que o de controle, as ações de controle foram consideradas constantes nos intervalos de amostragem acima do horizonte de controle. Foi aplicado o método *backpropagation* para treinamento da rede, e a técnica *steepest descent* para aceleração do método. A soma dos erros entre as saídas preditas e os valores de referência no horizonte de predição, foi definida como,

$$E = \sum_{j=1}^N e(k+j) = \sum_{j=1}^N \frac{1}{2} [y_{pred}(k+j) - y_{sp}(k+j)]^2. \quad (2.4)$$

A variável manipulada no período de amostragem  $k+i$ , reconhecida como  $u(k+i)$  foi ajustada, iterativamente, pelo método *steepest descent*, ou seja,

$$u(k+i)^{novo} = u(k+i) - \eta \frac{\partial E}{\partial u(k+i)} \quad (i=0, 1, \dots, M-1) \text{ até } E \leq \varepsilon, \quad (2.5)$$

onde  $\eta$  é o tamanho do passo e  $\varepsilon$  representa o critério de convergência. As restrições nas variáveis manipuladas receberam o seguinte tratamento: se a restrição for ultrapassada, então a variável manipulada assume o valor do limite; entretanto este limite pode ser ultrapassado, devido a variações de outras variáveis manipuladas, em função da interdependência destas variáveis.

Este processo foi aplicado em um sistema não linear, representado por um reator CSTR, numa reação exotérmica e irreversível, com uma cinética de primeira ordem. A rede utilizada para modelo foi composta de 2 nós de entrada ( $y(k)$  e  $u(k)$ ), 4 nós na camada

escondida e 1 nó na camada de saída ( $y(k+1)$ ), onde  $k$  representa o instante de amostragem presente e  $k+1$  representa o instante futuro. O método *backpropagation* incluiu o termo de momento no treinamento (*momentum*). Foram gerados 400 padrões para o treinamento, sendo necessário 1000 iterações para início de controle. Dos resultados obtidos da simulação, ele concluiu que o desvio encontrado entre o modelo e o sistema real foi devido a ausência de informações na região não estável, mas que o perfil do modelo acompanhou o perfil real. Para avaliar a influência do horizonte de predição na ação do controle, ele utilizou inicialmente  $N = 5$ , depois  $N = 10$  e  $N = 15$ , para horizonte de controle  $M = 1$ . Ele concluiu que a medida que aumenta o horizonte de predição, o controle fica mais estável, entretanto é necessário maior esforço computacional. Fazendo também uma análise utilizando  $M = 5$  com  $N = 5$ , chegou a resultado oscilatórios, concluindo que para controle de sistemas não estáveis é muito importante utilizar uma estratégia de estabilidade. Analisando o efeito de ruído no controlador, concluiu que o controlador foi capaz de estabilizar o sistema mesmo na presença de ruídos e distúrbios externos, apresentando porém um desempenho pior do que o mesmo sistema sem estas interferências. Em seu estudo, concluiu que a principal vantagem do método apresentado foi a utilização da mesma estrutura de rede neural tanto na modelagem da planta quanto na determinação da variável manipulada. No presente estudo é previsto utilizar RNA com o método de treinamento via *backpropagation* para identificação de um sistema não linear com restrições e com características MIMO, avaliando também a influência da presença de ruído no modelo. É previsto também avaliar a influência do horizonte de predição no desempenho do controlador, utilizando um critério baseado na técnica de tentativa e erro.

ENDER & MACIEL FILHO (2000) utilizaram redes neurais em estratégias de controle preditivo aplicadas a unidades de craqueamento catalítico em leito fixo, sendo observado o bom desempenho do controlador. Destaca-se aqui que o treinamento é feito inicialmente *off-line*, mas após início da atuação do controlador, o treinamento passa a ser feito *on-line*, na tentativa de capturar alterações no comportamento dinâmico do processo.

DE SOUSA JR. (1993) empregou uma RNA para classificação de processo onde a rede foi usada para prever as propriedades de um catalisador em função das condições do processo de fabricação. O autor também usa a rede para a identificação de reatores não lineares com controle preditivo. Em seu estudo foi usado o método *backpropagation* com a

técnica *steepest descent* como rotina de treinamento. Foi usado um programa desenvolvido em fontes de códigos computacionais em linguagem Fortran, baseado em um estudo de CASTIER (1990), que calcula o gradiente conjugado de FLETCHER e REEVES (1964, *apud* DE SOUZA JR., 1993). Ele acrescentou algumas rotinas a este programa, adaptando-o às suas condições. Este mesmo programa desenvolvido por CASTIER (1990), foi também utilizado por outros autores, a saber: FONSECA (1998), em sua dissertação de mestrado, num estudo onde as RNA foram usadas na identificação de um processo de fermentação alcoólica contínua, e SANTOS (2000b), que apresentou como tema de mestrado um estudo envolvendo a identificação da unidade FCC.

### 2.3 Proposta da Tese

No presente estudo, é previsto utilizar o mesmo programa desenvolvido por CASTIER (1990) e DE SOUZA JR. (1993) para identificação do modelo em RNA, sendo necessários alguns ajustes para adaptá-lo ao problema proposto. O método do gradiente conjugado foi o método escolhido para o treinamento das redes neurais, devido ao bom desempenho deste método nos testes preliminares efetuados e devido à prévia decisão de se efetuar um treinamento *off-line*, e, portanto, o tempo de treinamento não constituiria um fator limitante para o processo de identificação. Vale ressaltar que se o tempo de treinamento da rede fosse prejudicial ao processo na identificação da rede ou se fosse previsto um treinamento *on-line*, outro método poderia ser utilizado para treinamento (os métodos do gradiente conjugado, gradiente descendente com busca em linha, gradiente conjugado com passo fixo, quasi-Newton DFP - *Davidon-Fletcher-Powell* e quasi-Newton BFGS - *Broyden-Fletcher-Goldfarb-Shanno* estão disponíveis no programa). A decisão de usar um programa pronto para o processo de identificação em redes neurais foi útil pois economizou tempo que seria despendido na etapa de desenvolvimento de um *software* para criação da rede, que, no caso em questão, representa apenas uma ferramenta de cálculo e não constitui o principal propósito deste estudo. Tal prática de usar um programa pronto é comum em trabalhos de aplicação (GROSDIDIER *et al.*, 1993; ALI & ZAFIRIOU, 1993; ISHIKAWA *et al.*, 1997; RUIZ & SONNET, 2000; JAMIESON, 2001; GREAVES *et al.*, 2001; PEDROSA *et al.*, 2001), onde pacotes comerciais diversos disponíveis em grande número são freqüentemente utilizados (CHEN, 1990; BORGES & CASTIER, 1993, *apud* DE SOUZA JR., 1993).

O modelo fenomenológico, validado com os dados da unidade industrial por MORO (1992), foi desenvolvido a partir dos estudos de KURIHARA (1967). Este modelo, tendo em vista a boa concordância de seus resultados com os dados da unidade industrial, serviu de base para os trabalhos de MORO & ODLOAK (1995), AGUILARA *et al.* (1999), SANTOS (2000), ANSARI & TADÉ (2000), ZANIN *et al.* (2000a,b), entre outros, sendo portanto considerado adequado para o processo de identificação da FCC em Redes Neurais Artificiais. O modelo supra citado, devido ainda à disponibilidade do programa fonte e às facilidades de manuseio, será também usado como simulador da FCC para testar o controlador preditivo multivariável proposto.

Como estratégia desta tese é proposto inicialmente realizar a identificação do processo de FCC em redes neurais a partir do modelo fenomenológico disponibilizado por MORO (1992). O treinamento da rede será baseado num procedimento *Backpropagation* utilizando o método do Gradiente Conjugado. Diversas arquiteturas de rede serão obtidas e suas respostas comparadas com as respostas do modelo fenomenológico, sendo escolhidas aquelas que apresentarem melhor desempenho e menor tempo de CPU na etapa de treinamento. Posteriormente é proposto desenvolver um controlador preditivo multivariável (MPC), adotando como modelo a Rede Neural escolhida do processo de identificação. O método de minimização utilizado será obtido da rotina NCONF, disponível na biblioteca *IMSL* pertencente ao Fortran. Para avaliar o desempenho do controlador proposto, são previstos alguns testes efetuando perturbações no modelo fenomenológico de forma a avaliar as respostas do controlador, comparando-a com os resultados dessas mesmas perturbações com o sistema aberto e com as respostas obtidas do controlador DMC obtido por Moro.

## CAPÍTULO III

### MODELAGEM MATEMÁTICA DO PROCESSO

É apresentada aqui uma breve descrição do processo da unidade FCC, enfatizando as variáveis utilizadas no sistema de controle convencional existente e que serão também utilizadas no controle preditivo em redes neurais. Posteriormente são apresentados a metodologia empregada das redes neurais e o processo de identificação, e finalmente o procedimento do controle preditivo.

#### 3.1 Modelos que representam a unidade de FCC

Diversos estudos obtidos na literatura mostram modelos matemáticos onde se procura obter uma forma de representar a unidade de FCC. Entre esses modelos, que são utilizados como modelo em controladores preditivos, destacam-se os desenvolvidos por: MCFARLANE & REINEMAN (1990), GROSDIDIER *et al.* (1993), ALI & ELNASHAIE (1997), que utilizaram a FCC, Modelo IV da *EXXON*; LEE & KUGELMAN (1973) e HAN & CHUNG, (2001a,b) que utilizaram um modelo *side by side*; e MORO & ODLOAK (1995), onde utilizaram o modelo *Orthoflow F.* da M. W. Kellogg, o qual representa um modelo de 10 *Lumps* descrito inicialmente por Kurihara; dentre outros. Todos eles justificaram seu uso em função dessa unidade apresentar elevado valor agregado em seus produtos, com grande possibilidade de retorno de investimento, independente do modelo considerado.

HAN & CHUNG, (2001a,b) propuseram o desenvolvimento de um modelo dinâmico para a FCC, num primeiro estudo, e testes comparativos, em outro estudo, visando simular o regenerador e o reator. O reator foi considerado como modelo de 4 *Lumps* e o regenerador composto de duas fases, identificado como modelo *side by side*. O modelo foi criado de forma modular, onde cada módulo representou uma parte da unidade, descrita por equações diferenciais. Foi constatada a presença de mais de um estado estacionário para as condições normais de operação para este modelo de FCC, a depender do estado inicial na simulação. Citaram também que seu comportamento dinâmico é muito sensível à condição de ativação inicial do catalisador. Este modelo foi validado com valores

de estado estacionário obtidos da literatura, representando bem o processo físico e confirmando a elevada interação existente entre o regenerador e o reator.

### 3.2 Processo de Craqueamento Catalítico em Leito Fluido

Qualquer que seja o modelo considerado, a unidade de FCC apresenta como objetivo o de reduzir o tamanho das cadeias hidrocarbônicas das frações mais pesadas do Petróleo por meio de reações catalíticas.

O craqueamento catalítico utilizado em refinarias de petróleo é considerado o maior processo catalítico do mundo em função do volume processado e dimensões dos equipamentos utilizados. Este processo é útil, pois transforma produtos derivados de Petróleo de alto peso molecular e que apresentam baixo valor comercial agregado em produtos de maior valor comercial. Estas unidades apresentam normalmente um lucro líquido de US\$30/ton processada, o que equivale a um lucro líquido de US\$240.000/dia se considerarmos um processamento normal de 8.000 ton/dia (MORO, 1992).

Essa unidade recebe como carga as correntes provenientes principalmente das seguintes unidades de uma refinaria de petróleo: Destilação à Vácuo, as correntes de Gasóleo e Resíduo de Vácuo, e Unidade de Desasfaltação com Propano, como Óleo Desasfaltado. O petróleo e suas frações são constituídos por misturas bastante complexas de hidrocarbonetos, contendo inclusive heteroátomos com oxigênio, enxofre e nitrogênio (VENUTO & HABIB, 1978). Esta composição variada influencia diretamente na desativação do catalisador e na composição da gasolina produzida (PACHOVSKY & WOJCIECHOWSKI, 1975). A complexidade da carga de uma unidade de FCC torna impossível a modelagem cinética de cada uma das reações envolvidas, tornando necessário o agrupamento dos componentes em *lumps* (WEEKMAN, 1979). O modelo de dez *lumps* constitui hoje o mais completo modelo de craqueamento catalítico (JACOB *et al.*, 1976). Como produtos gerados, tem-se: Gás Combustível – hidrogênio, metano, etano e eteno; Gás Liquefeito de Petróleo (GLP) – propano, propeno, butanos e butenos; Nafta Craqueada – hidrocarbonetos de 5 ou mais átomos de carbono e que se destilam à temperatura de até 220°C; Óleo Leve de Reciclo (*Light Cycle Oil* – LCO) com destilação até 360°C; Óleo Decantado também denominado Óleo Combustível de FCC ou Óleo Combustível Craqueado, composto de hidrocarbonetos mais pesados que o Óleo Leve; e Coque – sólido de alto peso molecular e alto teor de carbono, geralmente com relação C:H de 1:1, sendo

queimado na própria unidade. Desses produtos, o que apresenta maior valor agregado é a Nafta Craqueada, utilizada como gasolina automotiva, sendo portanto esta a principal meta de uma unidade de craqueamento. Alternativamente, a unidade pode também ser direcionada para a produção de GLP.

O processo ocorre em temperaturas elevadas, na faixa de 500 a 550°C, em presença de um catalisador seletivo, à base de Zeólitas. O catalisador se apresenta na forma de um pó branco de diâmetro médio de 60µm, com elevada porosidade e área específica, e, por apresentar dimensões tão pequenas, escoia como se fosse um fluido, o que facilita seu manuseio, porém, com o inconveniente de provocar abrasão nos equipamentos e redução em seu diâmetro devido ao atrito.

Devido às condições de temperatura do reator, ocorrem também reações secundárias indesejáveis devido ao craqueamento térmico, como a formação de coque, polimerização e desidrogenação, com conseqüente deposição do coque sobre a superfície do catalisador, reduzindo sua atividade. Desta forma, torna-se necessária a regeneração do catalisador, o que é feito por meio de queima do coque depositado. Para isto, o catalisador é transportado da seção de reação para a seção de regeneração e daí volta para a seção de reação, por meio de transporte fluido.

A seguir (Figura 3.1) é apresentado um desenho esquemático mostrando a circulação do catalisador de uma planta industrial.

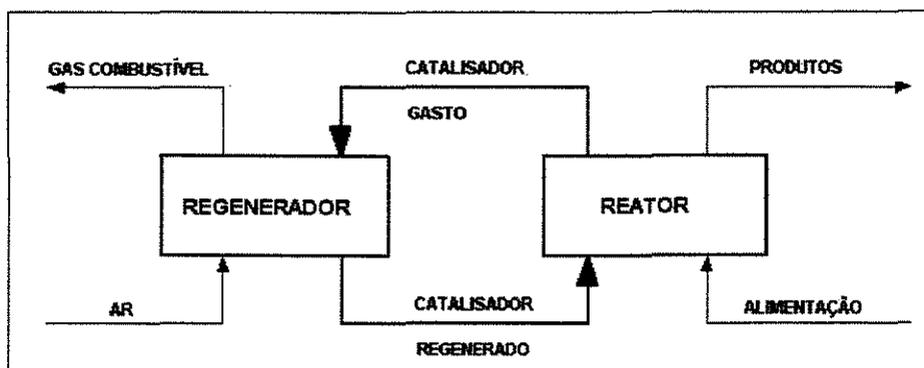


Figura 3.1 Circulação de Catalisador em uma Unidade de Craqueamento Catalítico.

Na seção de reação prevalecem as reações de quebra de cadeia que são endotérmicas, resultando em um consumo de energia. É nesta seção que ocorre também a

formação de coque que é depositado no catalisador reduzindo sua atividade. Na seção de regeneração o coque depositado no catalisador é queimado gerando energia e provocando sua reativação. A energia liberada nesta reação será utilizada para suprir a energia gasta na outra seção; daí, pode ser observada a importância de se realizar um balanço de energia entre estas seções para que sejam mantidas as condições de operação dentro dos limites de restrição do sistema, e de forma a garantir uma economia de energia. Outro balanço necessário neste processo é o balanço de carbono que faz com que a quantidade de coque gerada na seção de reação seja igual à quantidade queimada na outra seção. Além disso, é necessário ainda manter uma vazão de catalisador circulando entre as duas seções; para isto torna-se indispensável manter um perfil de pressões adequado, denominado de balanço de pressão. As equações de balanço de energia e massa da unidade de FCC, obtidas do modelo de KURIHARA (1967), e usadas para validar o modelo com a unidade industrial (MORO, 1992), estão mostradas no ANEXO D.

### ***3.2.1 Descrição de operação da unidade***

A seguir é feita uma descrição da operação da unidade de craqueamento catalítico. Para acompanhá-la é utilizado um esquema representando o conversor FCC da *Kellogg Orthoflow F.* da Refinaria Henrique Lages (Figura 3.2). Apesar de representar esta unidade específica, os princípios aqui descritos são similares a qualquer outro modelo (MORO, 1992).

A carga após ser aquecida até uma temperatura adequada, na faixa de 200 a 300°C, é injetada na base do reator tubular, conhecido como *Riser*, utilizando-se também vapor d'água para facilitar a dispersão dos hidrocarbonetos em gotículas. Devido ao contato com o catalisador quente (cerca de 700°C) proveniente do regenerador, a carga é rapidamente vaporizada dando início às reações de craqueamento. A vaporização faz com que a mistura carga e catalisador siga a direção ascendente ao longo do *Riser*, com velocidade média de 20 m/s, o que fornece um tempo de residência em torno de 2 segundos nesta etapa do reator. À saída do *Riser*, com temperatura em torno de 540°C, a mistura penetra no vaso separador, também chamado de reator, onde sofre desaceleração até aproximadamente 0,5 m/s, provocando a separação de hidrocarbonetos e catalisador. Os hidrocarbonetos passam através de um conjunto de ciclones de duplo estágio, visando reter as partículas

mais finas de catalisador que tenham sido arrastadas e são enviados para a seção da unidade onde será feita a separação entre as várias frações por meio de destilação.

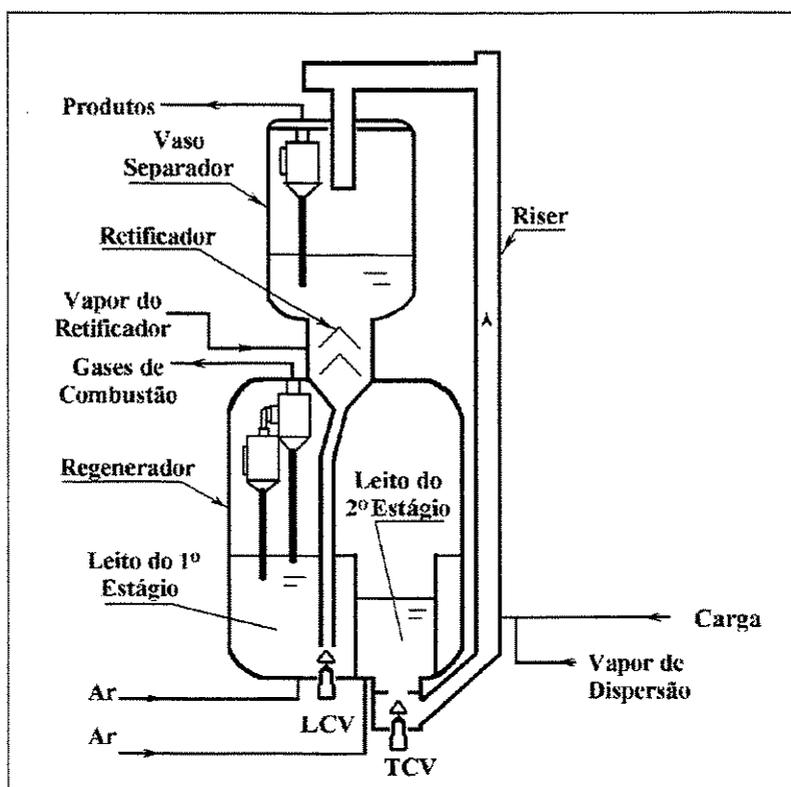


Figura 3.2 Desenho esquemático da Unidade de Craqueamento Catalítico da Kellogg Orthoflow F. pertencente à Refinaria Henrique Lage, situada em S. José dos Campos - SP.

O catalisador forma um leito no fundo do vaso separador, iniciando um fluxo descendente. O catalisador nesta fase está impregnado de coque e de hidrocarbonetos mais pesados que podem ainda ser recuperados, o que é feito no retificador ou *stripper*, através de injeção de vapor d'água. A seguir o catalisador passa por um tubo vertical conhecido como *stand-pipe*, o qual possui em sua base uma válvula, denominada de válvula de catalisador gasto, que manipula a vazão que chega ao primeiro estágio do regenerador. Neste ponto a injeção de ar dá início à combustão do coque, reduzindo o seu teor da faixa de 1,0% em massa para cerca de 0,25% em massa, com elevação da temperatura até aproximadamente 680°C. O catalisador flui para o segundo estágio de regeneração, onde é injetado mais ar e o teor de carbono cai para 0,1% em massa, atingindo temperaturas em torno de 700°C.

Os gases de combustão, contendo quantidade apreciável de monóxido de carbono (em torno de 10% vol.), passam através de um conjunto de ciclones e são enviados, após redução da pressão, para uma caldeira onde o CO é queimado para gerar vapor d'água de alta pressão. A presença de CO nos gases de combustão faz com que ocorra a sua oxidação na fase diluída do regenerador, provocando elevação de temperatura nesta região.

O catalisador, já regenerado é enviado para a base do *Riser*, com vazão controlada por uma válvula (válvula de catalisador regenerado), onde o ciclo se repete.

### 3.2.2 Estratégia de controle do FCC

Inicialmente, é apresentada uma descrição do controle convencional da unidade FCC, para auxiliar na descrição do processo. Para isto, a Figura 3.3 a seguir será útil para entendimento deste controle.

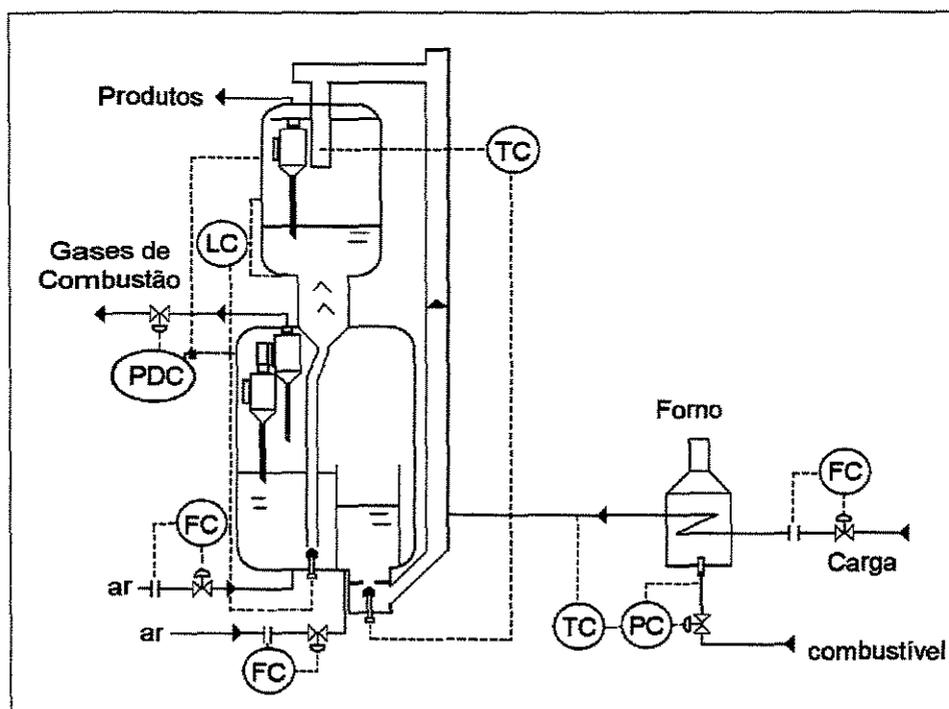


Figura 3.3 Esquema do controle convencional da unidade de Craqueamento Catalítico.

A carga, normalmente proveniente do sistema de tancagem da unidade, apresenta um controle de vazão independente. Ela é aquecida em permutadores de calor e posteriormente em um forno de aquecimento de carga. A temperatura da carga na saída do forno é controlada por meio de um controle de vazão de combustível para o forno. A

temperatura de saída do *Riser* é controlada pela válvula de admissão de catalisador regenerado. O nível de catalisador no vaso separador é controlado pela válvula de catalisador gasto. As temperaturas dos leitos, fases densas e diluídas são controladas pela vazão de ar para regeneração. O diferencial de pressão dos subsistemas reação e regeneração, indiretamente a pressão do regenerador, é controlado pela válvula de gases de combustão.

Visando manter a unidade operando em condições de estabilidade e continuidade desejadas, é necessário o controle de alguns parâmetros do processo. A seguir são apresentados os controles mais relevantes de uma unidade de FCC, juntamente com sua justificativa de controle (MORO, 1992; GROSDIDIER *et al.*, 1993):

- **Concentração de  $O_2$  no gás de combustão** – Excesso de  $O_2$  no gás de combustão representa um desperdício econômico, uma vez que é gasta energia para soprar ar para dentro do vaso regenerador. Por outro lado, insuficiente quantidade de  $O_2$  pode levar o regenerador à queima parcial, produzindo mais CO junto com  $CO_2$ . Apesar do regenerador operar frequentemente com queima parcial, a operação em região intermediária entre os dois modos de queima representa uma região instável. Esta instabilidade deve ser evitada mantendo um teor mínimo de  $O_2$  no gás de combustão. Na impossibilidade de se ter um analisador de linha acoplado ao sistema para este controle, o mesmo pode ser feito indiretamente por meio do controle de temperatura da fase diluída, o qual por sua vez, é feito controlando as temperaturas dos leitos densos nos 1<sup>o</sup> e 2<sup>o</sup> estágios de regeneração.
- **Capacidade do soprador de ar** – A capacidade de queima do coque depositado no regenerador, e portanto, a capacidade de alimentação da unidade, pode ser limitada pela capacidade do soprador de ar. O controle da capacidade deste soprador é efetuado pela regulagem do ângulo das lâminas do soprador, o qual não pode exceder determinado limite inferior e superior. Esta capacidade é também indiretamente limitada pela velocidade superficial máxima permitida no regenerador. Esta velocidade superficial deve ser mantida abaixo de um limite para prevenir entrada excessiva de ar através do leito fluidizado. Tal situação pode criar condições de queima acima da seção do regenerador ou então dentro dos ciclones, fenômeno denominado de queima posterior ou *afterburn*. Isto ocorre quando uma boa parte da combustão ocorre na região do

regenerador acima do leito, e isto pode acontecer quando o tempo de residência do  $O_2$  é baixo devido à elevada velocidade superficial. A oxidação do CO neste caso é completada fora do leito fluidizado;

- **Temperatura do leito do regenerador** – A temperatura dentro do leito do regenerador varia ao longo do eixo vertical do vaso, sendo tipicamente mais baixa no fundo do leito e alta na câmara e na linha de saída de gás combustível. Apesar da câmara apresentar picos momentâneos de temperatura alta devido a ocorrência de queima acima do leito, denominada de *afterburn*, em geral esta temperatura apresenta um perfil bem comportado; isto significa que é suficiente controlar apenas uma temperatura, no caso, o controle da temperatura do leito denso é suficiente para estabilizar todo o perfil. Esta temperatura, entretanto, não necessariamente deve ser fixada por um valor de referência, mas sim deve ser mantida dentro de limites de controle. Ela não deve ser muito alta para que a temperatura da câmara não atinja os limites de resistência mecânica dos ciclones e da linha de gás combustível. Além disso, a circulação de catalisador diminui com o acréscimo da temperatura do leito, uma vez que menos catalisador será necessário para manter a temperatura do *Riser* dentro do objetivo de controle. Desta forma, uma temperatura muito alta no leito decresce a razão catalisador/óleo, o que causa efeitos indesejáveis nos produtos de saída, como por exemplo, reduz a conversão (ou severidade) da reação. Por outro lado, a baixa temperatura do leito denso é também não desejável pois pode forçar a abertura total da válvula de catalisador regenerado, válvula esta que permite a circulação do catalisador do regenerador para o leito do reator limitando assim a capacidade de processamento da unidade;
- **Temperatura do Riser** – Duas restrições de operação limitam a capacidade do controlador de temperatura de saída do *Riser* em manipular a válvula de catalisador regenerado:
  - A saída do controlador é primeiramente restringida pela necessidade de manter esta válvula dentro da faixa de controlabilidade. Além de uma certa posição máxima de abertura, qualquer deslocamento excedente não produz nenhum efeito significativo na temperatura de saída do *Riser*. A válvula é então dita estar saturada.

- A saída do controlador é também restringida pela necessidade de manter um diferencial mínimo de pressão através da válvula. Este  $\Delta P$  é obrigatório para prevenir um fluxo reverso acidental, evitando assim a entrada de óleo de alimentação no leito regenerador ao invés de entrar no *Riser*, o que teria efeito catastrófico, dado à presença de oxigênio associado à elevada temperatura deste leito;
- ***Pressão de sucção do Compressor de Gás Úmido*** – A capacidade de processamento da unidade pode ser limitada pela habilidade do compressor de gás úmido em processar a principal fração vaporizada. Sua capacidade é limitada pela necessidade de manter o controle de pressão (posição de abertura da válvula de vapor) dentro de seu limite de controlabilidade. Ultrapassada uma certa posição máxima de abertura, a válvula de vapor falha em controlar o fluxo de vapor para a turbina que aciona o compressor de gás úmido. Esta situação previne o compressor de ter condição suficiente de controle para manter a pressão de sucção nos valores desejados;
- ***Gás combustível produzido*** – Esta restrição final surge na unidade de recuperação de vapor. Excessiva carga processada ou elevada temperatura produz mais óleo combustível do que pode ser recuperado no absorvedor da unidade de recuperação de vapor.

É importante que se entenda que nem todas as restrições são encontradas simultaneamente durante a operação da unidade. Uma carga mais pesada, por exemplo, pode gerar uma quantidade maior de coque e relativamente pouco gás de craqueamento. Isto sobrecarrega o soprador de ar e faz aumentar a temperatura do leito, mas deixa a temperatura de saída do *Riser* e a pressão de sucção do compressor bem dentro de suas faixas de controlabilidade. Reciprocamente, uma carga leve tende a forçar estas duas saídas de controle até seus limites enquanto alivia a operação do soprador.

### **3.3 As Redes Neurais Artificiais**

A Inteligência Artificial (IA) é um campo da ciência da computação concebida para o projeto de sistemas de computadores inteligentes, isto é, sistemas com características que associamos à inteligência no comportamento humano. Em termos práticos, IA trata do processamento por métodos não algorítmicos, simbólicos de resolver problemas

(BAUGHMAN & LIU, 1995). O processamento simbólico é a base para algumas aplicações da IA (PRETT & GARCIA, 1988); nela, o conhecimento é extraído e representado simbolicamente por regras. As redes neurais são subgrupos de programas e rotinas computacionais que fazem parte da IA. Este subgrupo, por ser parte integrante do tema dessa tese, será descrito a seguir. Alguns autores associam as Redes Neurais Artificiais com as células neuronais existentes nos seres vivos de origem animal, inclusive alguns termos e conceitos utilizados para caracterizar as RNA são tomados emprestados dessas células. É recomendado ao leitor que tiver interesse em conhecer algumas dessas comparações realizadas, que procurem uma literatura adequada como NELSON & ILLINGWORTH (1991). Dando continuidade ao estudo, a seguir são apresentadas as RNA, iniciando com um resumo desta técnica e uma síntese da rede proposta, descrevendo o método de treinamento utilizado. Posteriormente é feita uma descrição do método de Controle Preditivo com Modelo, enfocando o Modelo de Redes Neurais Artificiais.

### ***3.3.1 Arquitetura das redes multicamadas***

Na tentativa de reproduzir os mecanismos de entendimento de como são assimiladas as informações no próprio cérebro, foram desenvolvidos os processos subsimbólicos, que são modelos matemáticos aplicados a um sistema devidamente arrumado. São as chamadas Redes Neurais ou Neuronais Artificiais. Definindo genericamente o que seja rede neural, utilizando uma analogia com o cérebro humano, podemos dizer que é "... uma distribuição densa de elementos processadores (também chamados de nós, neurônios, memórias de curto alcance, etc.) dispostos em camadas e interconectados através de canais unidirecionais – as conexões ...", essas conexões são também chamadas de Sinapses (DE SOUZA JR, 1993; HAYKIN, 1994).

Estas conexões apresentam uma certa liberdade de arquitetura ou topologia, que é a forma como os neurônios artificiais estão conectados. De maneira geral, existem três opções de conexões de neurônios, que são: intracamadas, intercamadas e recursivas (BAUGHMAN & LIU, 1995), conforme mostrados nas representações da Figura 3.4 a seguir.

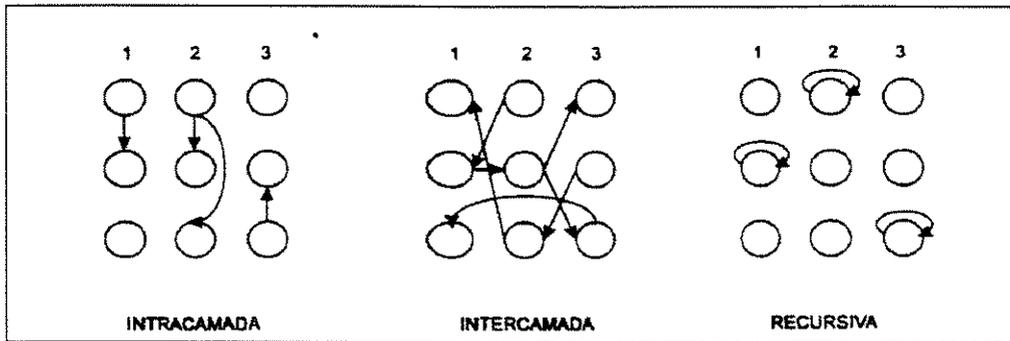


Figura 3.4 Formas de conexão dos neurônios artificiais. 1, 2 e 3 representam as camadas de entrada, intermediária ou escondida e de saída, respectivamente.

As redes neurais podem ser caracterizadas por 3 partes principais: - a topologia da rede; - a característica computacional de seus elementos; e, - a regra de treinamento (HERNÁNDEZ & ARKUN, 1992). Referente à topologia (ou arquitetura), podem ser identificados pelo menos 4 diferentes classes de arquitetura, as quais estão intimamente ligadas à forma de treinamento a que estão submetidas. A topologia a que estamos interessados no presente estudo, denominada de “redes multicamadas *feedforward*” é destacada a seguir:

- **Rede multicamada *feedforward*.** Nesta arquitetura é observada a presença de uma ou mais unidades ou camadas escondidas. O termo *feedforward* (alimentação para frente ou direta) representa um tipo particular de ligação entre as camadas. Os neurônios das camadas escondidas ficam entre a camada de entrada e a camada de saída e seu objetivo é conseguir extrair da rede resultados estatísticos de alta ordem, que se tornam úteis por exemplo quando o número de neurônios de entrada é muito grande (HAYKIN, 1994). Nesta topologia também é notado o paralelismo do modelo. Os sinais provenientes da camada de entrada, também denominados de fonte, suprem os neurônios da camada escondida (primeira camada escondida, se houver mais de uma); daí, os resultados das operações realizadas nesta camada (vetores de saída dos nós) são sinais de entrada da próxima camada. Desta forma, o conjunto de sinais (respostas) obtidos na saída da rede (após passar por todas as camadas), denominado resposta global da rede, será comparado com padrões supridos pelos nós fontes da primeira camada. Existem duas formas de se conectar os nós de uma camada com a outra nesta configuração *feedforward*: totalmente conectada e parcialmente conectada; uma rede com arquitetura de multicamadas, por exemplo, pode ser totalmente conectada, caso cada nó de uma

camada esteja conectado com todos os nós da camada seguinte, ou, caso contrário, a rede será parcialmente conectada, conforme representado na Figura 3.5. Uma das formas da rede neural *feedforward* parcialmente conectada que apresenta um certo interesse é a localmente conectada, ou seja, os nós são conectados apenas aos neurônios da vizinhança. O tipo localmente conectado é útil quando se sabe *a priori* que apenas alguns neurônios de entrada (não todos eles) exercem influência em determinada resposta de saída, e os demais exercem pouca ou nenhuma influência nessas respostas, e se deseja reduzir o tempo computacional no processo de treinamento. Os demais tipos de topologia normalmente encontrados são: rede de simples camada *feedforward*, redes recorrentes e redes em estruturas *lattice*.

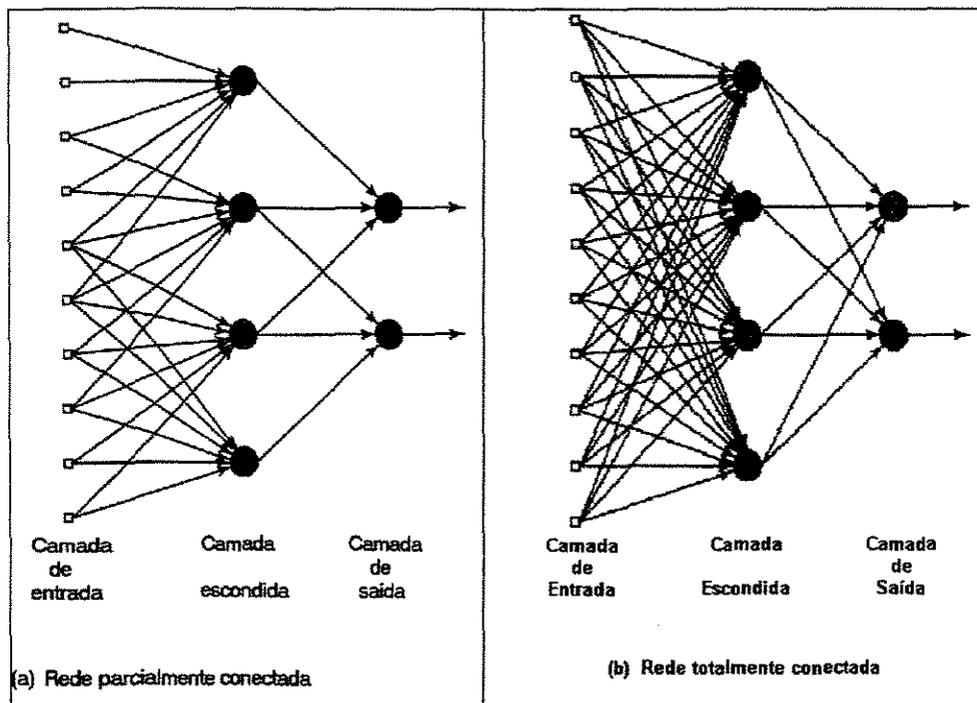


Figura 3.5 Redes multicamadas *feedforward* exemplificado para o caso de 3 camadas (a) parcialmente conectada e (b) totalmente conectada.

Convém esclarecer que para cada arquitetura de rede, há um método de treinamento específico, o que envolve uma rotina computacional própria; dessa forma, quando não existem restrições quanto ao tempo processamento de computador gasto no treinamento, ou quando não se consegue precisar a influência relativa de cada variável de entrada nas respostas de saída, uma boa estratégia de programação é utilizar uma rotina

computacional baseada numa estrutura de rede multicamada totalmente conectada, e deixar por conta do próprio treinamento a decisão da influência de cada nó nos resultados.

A rede proposta neste estudo apresenta a seguinte topologia: rede multicamada totalmente conectada, com os sinais passando em uma única direção (da entrada para a saída), caracterização *feedforward*, com apenas ligações intercamadas, apresentando 3 camadas denominadas respectivamente de camada de entrada, camada escondida e camada de saída (*input, hidden and output layers*). O número de neurônios na camada de entrada será definido como sendo igual ao número de variáveis pertinentes do sistema em questão (denominadas de variáveis controladas e manipuladas); na camada intermediária, utilizando a técnica de tentativa e erro, será buscado qual o número mínimo de neurônios que fornece menor erro quadrático, e ao mesmo tempo, que apresenta resultados satisfatórios, baseados num critério de desempenho preestabelecido; na última camada, o número de neurônios será definido como sendo igual ao número de variáveis controladas preditas do sistema em questão. Uma vez definida a topologia que a rede irá ter, agora pode ser explicado o funcionamento de um neurônio em uma rede multicamada qualquer.

Acompanhando a Figura 3.6 a seguir, tem-se um neurônio  $j$  qualquer da camada  $k+1$ . Este neurônio recebe um conjunto de informações  $S_{pi,k}(i=1, \dots, n_k)$ , correspondente às saídas, ou ativações, dos  $n_k$  neurônios da camada anterior, que são ponderadas pelo peso  $w_{jik}$  correspondente à sua conexão. O neurônio soma essas entradas ponderadas e o valor resultante é por sua vez somado a um limite interno de ativação, um *bias* (também denominado em determinadas redes de *threshold*) que é representado por  $\theta_{j,k+1}$ . Ao resultado dessa soma é aplicada uma função denominada de função de transferência. A este sinal resultante, o neurônio  $j$  produz uma resposta representada por  $S_{pj,k+1}$  (DE SOUZA JR, 1993; HAYKIN, 1994).

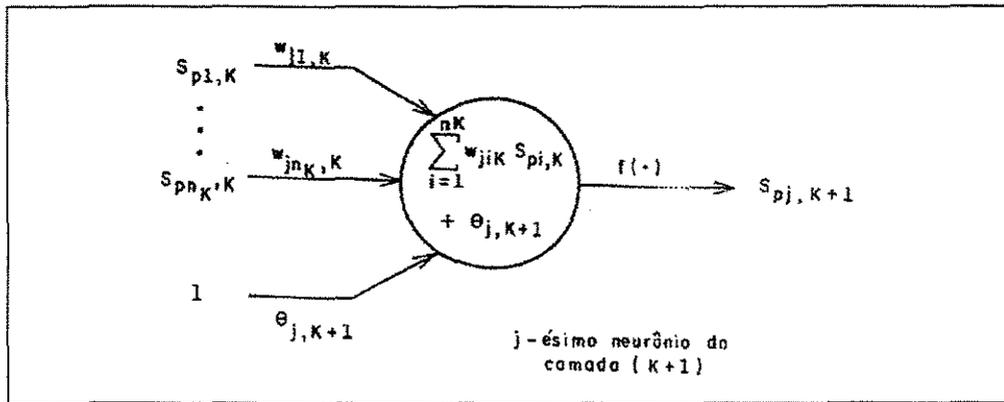


Figura 3.6 Representação esquemática de um neurônio qualquer pertencente à camada  $k+1$ .

Matematicamente, pode-se expressar o comportamento de um neurônio por:

$$\lambda_{pj,k+1} = \left[ \sum_{i=1}^{n_k} w_{jik} \cdot S_{pi,k} \right] + \theta_{j,k+1} \quad (3.1)$$

Dois tipos de função são normalmente usados para a ativação dos neurônios, o tipo global e o local.

A função de ativação global produz uma saída para um largo intervalo de entradas. Como exemplos de função de ativação, tem-se:

- linear:  $f(\lambda_{pj,k+1}) = \lambda_{pj,k+1}$ ; (3.2)

- degrau limiar:  $f(\lambda_{pj,k+1}) = \begin{cases} +\xi & \text{se } \lambda_{pj,k+1} > 0 \\ -\zeta & \text{se } \lambda_{pj,k+1} \leq 0 \end{cases}$ , (3.3)

freqüentemente, no caso de degrau limiar,  $f(\lambda_{pj,k+1})$  é de natureza binária, ou seja,  $\xi = 1$  (um) se  $\lambda_{pj,k+1} > 0$  e  $\zeta = 0$  (zero) para os demais casos;

- função *sigmoidal*:  $f(\lambda_{pj,k+1}) = \left[ 1 + \exp(-\lambda_{pj,k+1}) \right]^{-1}$ ; (3.4)

- função tangente hiperbólica:  $f(\lambda_{pj,k+1}) = \tanh(\lambda_{pj,k+1})$ . (3.5)

As funções locais são aquelas que só apresentam uma resposta ativa para valores de entrada na vizinhança imediata do seu centro de ativação. Entre as funções desta natureza destaca-se a função gaussiana.

- função gaussiana:  $f_{pj} = \prod_{i=1}^{n_k} \exp \left[ \frac{(S_{pi,k} - \mu_{ji})^2}{-2\sigma_j^2} \right]$ ; (3.6)

com  $\sigma_j$  indicando a largura (desvio padrão) da gaussiana e  $\mu_{ji}$  os centros adaptativos da mesma, os quais podem ser fixados em  $\mu_j$  (WEIGEND *et al.*, 1990 *apud* DE SOUZA JR., 1993).

A função de ativação a ser utilizada neste estudo é a função *sigmoidal* (Equação 3.4). Esta função é a mais amplamente empregada como função de transferência em redes neurais (NELSON & ILLINGWORTH, 1991; DE SOUZA JR, 1993; HAYKIN, 1994). Para quaisquer valores apresentados à rede, esta função limita suas respostas entre [0,0 e 1,0]; desta forma, para tornar as respostas da rede compatíveis com as respostas do processo, é necessário normalizar todos os padrões apresentados à rede nesta faixa. A Figura 3.7, a seguir, apresenta um exemplo da função de ativação *sigmoidal* (BAUGHMAN & LIU, 1995). Nesta figura pode ser observado o caráter contínuo e portanto diferenciável da função *sigmoidal*, e também pode ser observada a limitação das respostas  $\varphi(v)$  entre 0,0 e 1,0, para quaisquer valores de  $v$ .

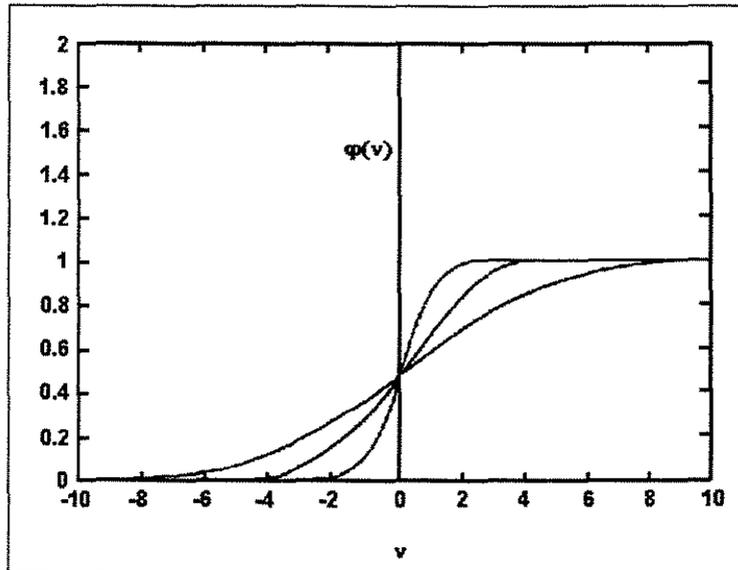


Figura 3.7 Exemplos de função de ativação do neurônio tipo *sigmoidal* (BAUGHMAN & LIU, 1995).

A aprendizagem da rede, ou treinamento, corresponde ao processo onde os pesos e *bias* são modificados (SIMPSON, 1990). Existem dois tipos de aprendizagem: o supervisionado e o não supervisionado. Os métodos mais empregados para treinamento de uma rede são os chamados supervisionados, onde a rede aprende por experiência, isto é, exemplos conhecidos de entrada e saída são apresentados à rede, que ajusta seus pesos de modo a se adaptar a estes exemplos. No treinamento não supervisionado, a rede não usa nenhuma influência externa para ajustar seus pesos, ao contrário, existe um monitoramento interno de desempenho, ou seja, a rede procura por regularidades ou tendências dos sinais de entrada fazendo adaptações dos pesos de acordo com funções da rede, mesmo sem saber se está indo na direção certa ou errada (NELSON & ILLINGWORTH, 1991). Desta forma a rede pode prever saídas para novas entradas. Por construção, os neurônios de uma mesma camada não se interligam diretamente, por conseguinte a rede apresenta um certo paralelismo; outra característica apresentada é que os dados são distribuídos, ou seja, mesmo que alguns neurônios sejam removidos, o desempenho global da rede poderá ser pouco alterado. A rede descrita desta forma, no que diz respeito ao paralelismo, guarda certa semelhança, mesmo que vaga, com o comportamento paralelo do mecanismo cerebral.

A arquitetura da rede, no que diz respeito a ser totalmente ou parcialmente conectada ou referente ao número de camadas, é escolhida em função do processo que se deseja representar. O desempenho global da rede é função, principalmente, da topologia escolhida para camada escondida, sendo influenciada pelo número de camadas escondidas existentes e pelo número de nós nestas camadas. Geralmente, o aumento do número de nós numa camada escondida não aumenta tanto o tempo de treinamento quanto o aumento do número de camadas escondidas. De acordo com a literatura, uma única camada escondida geralmente é suficiente para representar qualquer função não linear, bastando para isto utilizar um número adequado de nós nesta camada (NIKRAVESH *et al.*, 1996). A seguir é apresentado o método de treinamento proposto.

### ***3.3.2 Método de Treinamento Backpropagation***

Antes do treinamento propriamente dito, é necessário definir o tipo de treinamento a ser implementado ao sistema. A utilização de RNA para identificação de sistemas se apresenta em duas fases distintas: uma fase de aprendizado do sistema, onde são obtidos os pesos e *bias* das conexões das RNA, e outra, que pode ser denominada de fase de uso da rede treinada, onde a RNA treinada é usada para representar o sistema que foi identificado. A etapa de treinamento, dependendo do próprio sistema que se deseja representar, pode consumir um tempo de processamento computacional (*CPU time*) excessivamente elevado tornando essa etapa muito lenta para ser implementada em linha (*on-line*). Dessa forma, o procedimento de aprendizado da rede neural pode ser efetuado fora do processo (*off-line*). Na outra etapa, fase de uso da rede treinada, o tempo é normalmente da ordem de frações de segundo, o que permite sua implementação *on-line*. Neste estudo é previsto treinamento *off-line* de forma a definir a arquitetura da rede; nesta etapa é determinado também o número de neurônios necessários na camada escondida, o número de padrões necessários para identificação do modelo e também o tempo e o intervalo de amostragem, a partir de um procedimento com base na tentativa e erro. A fase de uso da rede treinada, obviamente será realizada *on-line*.

Para descrever a etapa de treinamento emprestaremos outra característica do comportamento do cérebro: a capacidade de aprender através do uso de exemplos, fazendo uma analogia com o computador. O método do aprendizado em redes neurais representa uma técnica muito utilizada para armazenagem do conhecimento. Para armazenar este

“conhecimento” no computador, podemos empregar a técnica do uso de exemplos. Para o treinamento (também chamado de aprendizado) é necessário criar uma rede neural; desta forma foi criada a rede multicamadas *feedforward*. A característica típica deste tipo de rede é ser formada por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída, conforme já dito; o sinal se propaga através da rede na direção para frente camada a camada. Esta rede neural é normalmente referida como sendo *Perceptrons* multicamadas (*Multilayer Perceptrons – MLPs*). O MLPs possui 3 características distintas:

- O modelo de cada neurônio na rede apresenta uma não linearidade na saída final. Esta não linearidade é suave, isto é, a função é diferenciável em toda extensão;
- A rede contém uma (ou mais) camada(s) de neurônios escondidos;
- A rede apresenta alto grau de conectividade, determinado pelas Sinapses (ligações) dos neurônios.

Este modelo tem sido aplicado com sucesso na solução de diversos problemas complexos por meio de treinamento utilizando o algoritmo popularmente conhecido – *error backpropagation algorithm* ou simplesmente *backpropagation*, que é baseado na técnica de correção do erro por aprendizagem (RUMELHART, *et al.*, 1986; WHITELEY & DAVIS, 1992).

Basicamente, esse processo de treinamento consiste em duas passadas pela rede em diferentes direções; uma na direção para frente e outra para trás. Na direção para frente o vetor de entrada aplica um sinal padrão de atividade nos nós da rede e seu efeito se propaga através da rede camada a camada. Então um conjunto de respostas é produzido na última camada (camada de saída da rede). Nesta passagem os pesos são todos fixados. Após comparação do sinal de resposta com o valor desejado, cria-se um erro. Este erro é o responsável pelo método de correção dos pesos da rede. Na correção, o erro retorna através da rede (segunda passagem ou passagem de retorno) onde os pesos são ajustados de acordo com uma regra preestabelecida de correção de erro. Esta regra tem como objetivo fazer com que a resposta da rede caminhe na direção da resposta desejada, diminuindo desta forma o erro a cada passada (DE SOUZA JR., 1993; HAYKIN, 1994).

No método *backpropagation*, na fase de aprendizagem, são fornecidas várias entradas conhecidas e respectivas saídas e os pesos das conexões são modificados até que

as saídas calculadas sejam próximas numericamente das saídas desejadas. Em notação matemática, isto equivale a:

$$E = \sum_{p=1}^{N_p} E_p \quad (3.7)$$

onde  $E_p$  representa o erro entre o valor desejado de cada padrão e o encontrado pela rede, e é fornecido por:

$$E_p = \frac{1}{2} \sum_{l=1}^{n_L} (s_{pl,L} - t_{pi})^2 \quad (3.8)$$

O método do gradiente descendente usa a informação do gradiente para calcular a direção de busca, ou seja, como o valor do gradiente determina a direção crescente da função, o negativo do gradiente irá determinar a direção descendente máxima da função. Minimizando a função erro (global ou local), obtém-se:

$$\underline{\nabla E(\underline{w})} = \underline{0} \quad (3.9)$$

No processo de otimização foi empregada a estratégia de *steepest descent* (RUMELHART & MCCLELLAND, 1986 *apud* DE SOUZA JR., 1993; HAYKIN, 1994). Este método é descrito como se segue para a k-ésima iteração,

$$\Delta \underline{w}_{k+1} = -\eta \underline{\nabla E}(\underline{w}_k) \quad (3.10)$$

onde,  $\underline{w}$  é o vetor de variáveis independentes de otimização, ou seja, pesos e *bias*, e o parâmetro de ajuste  $\eta$  é a taxa de aprendizagem (tomado como valor fixo, positivo e menor do que 1,0).

As duas fases do treinamento via *backpropagation* visam atualizar os pesos das conexões. O algoritmo proposto é apresentado no ANEXO A. Depois da rede treinada, pode-se então proceder à segunda etapa que é a fase de utilização da rede, a qual corresponde às equações A.1 a A.5 do referido anexo.

Uma característica inerente ao método *backpropagation* é que ele, em alguns casos, pode se tornar excessivamente lento, quando por exemplo, os passos usados na correção dos pesos e *bias*, são pequenos. Em outros casos, apresentam oscilações nos pesos, quando estes mesmos passos são muito grandes e a resposta se aproxima do valor desejado. Para evitar as oscilações, soma-se um termo de momento à Equação 3.10; desta forma tem-se,

$$\Delta \underline{w}_{k+1} = -\eta \nabla E(\underline{w}_k) + \varepsilon \Delta \underline{w}_k \quad (3.11)$$

Contudo, a equação acima, para  $\varepsilon$  fixo, pode não ser suficiente para resolver problemas de oscilação. Em vista disto, vários trabalhos foram desenvolvidos visando contornar estas dificuldades de convergência; estes trabalhos podem ser agrupados entre duas linhas principais. A primeira delas corresponde a trabalhos onde são sugeridas modificações apenas na implementação e não no algoritmo do método convencional; a outra linha de trabalhos abrange aqueles onde o problema de treinamento de uma rede neural é reestruturado usando estratégias tradicionais de engenharia, como por exemplo, no estudo de FILKIN, 1989 (*apud* DE SOUZA JR., 1993), no qual o treinamento é visto como uma evolução contínua de  $\underline{w}$  no tempo, sendo expresso por equações diferenciais ordinárias que são resolvidas usando uma rotina – DIVPAG – da biblioteca IMSL (*IMSL, Inc., Houston, Texas apud* DE SOUZA JR., 1993). Esta segunda linha de ação é mais utilizada, principalmente porque o treinamento é considerado por muitos um problema de otimização não linear.

Algumas propostas têm surgido na literatura de um ajuste menos empírico da taxa de aprendizado, destacando o uso do método *steepest descent* com ajuste dinâmico de  $\eta$  ( $\varepsilon = 0$ ) através de busca unidimensional (WATROUS, 1987 *apud* DE SOUZA JR., 1993). Os autores LEONARD & KRAMER, 1990 (*apud* DE SOUZA JR., 1993) propuseram um método de gradiente de direções conjugadas, com  $\eta$  e  $\varepsilon$  ajustados dinamicamente. A direção de busca  $S$  na iteração  $k+1$  é gerada recursivamente como segue:

$$S_0 = -\nabla E(W_0) \quad (3.12)$$

$$S_{k+1} = -\nabla E(W_{k+1}) + \varepsilon S_k \quad (3.13)$$

$$\varepsilon = \frac{[\nabla E(W_{k+1})]^T \nabla E(W_{k+1})}{[\nabla E(W_k)]^T \nabla E(W_k)} \quad (3.14)$$

onde o vetor dos pesos  $W_{k+1}$  foi determinado usando-se uma busca unidimensional (interpolação quadrática) para  $\eta$ ,

$$W_{k+1} = W_k + \eta S_k \quad (3.15)$$

O método utilizado de busca para  $\eta$  elimina as oscilações observadas no método do gradiente descendente com passo fixo.

Outros trabalhos ainda adotam o método de Newton, no qual a direção de busca leva em conta informações de segunda ordem sobre a função objetivo. Nesse método, a equação 3.9 pode ser rescrita,

$$\nabla E(\underline{w}_k) + H(\underline{w}_k) \Delta \underline{w}_k = \underline{0} \quad (3.16)$$

de modo que,

$$\Delta \underline{w}_k = -[\underline{H}(\underline{w}_k)]^{-1} \underline{\nabla} E(\underline{w}_k) \quad (3.17)$$

o que é equivalente à,

$$\underline{H}(\underline{w}_k) \Delta \underline{w}_k = -\underline{\nabla} E(\underline{w}_k) \quad (3.18)$$

onde  $\underline{H}$  é a matriz Hessiana (matriz das derivadas segundas parciais da função objetivo em relação às variáveis independentes de otimização) (EDGARD & HIMMELBLAU, 1988, *apud* DE SOUZA JR., 1993). Os valores de  $\underline{\nabla} E(\underline{w}_k)$  representam o gradiente do erro em função das variáveis independentes (pesos e *bias*) do método *steepest descent*, e são apresentados no ANEXO B.

O método de *steepest descent* corresponde a um caso particular do método de Newton, onde a Hessiana foi substituída por um escalar (DE SOUZA JR., 1993).

A rotina computacional usada para identificação do processo em redes neurais foi desenvolvida por CASTIER (1990)<sup>1</sup>, baseada em uma rotina de minimização da função multivariável usando algoritmo do gradiente conjugado de FLETCHER e REEVES (1964)<sup>2</sup> e revisada por De SOUZA JR. (1996). Esta rotina foi utilizada por CASTIER (1990), De SOUZA JR. (1993), FONSECA (1998) e SANTOS (2000). A utilização de rotina pronta ao invés de desenvolver o próprio modelo constitui uma prática comum, conforme já dito, e possibilita redistribuir melhor o tempo disponível para outras atividades.

### 3.3.3 Identificação em Redes Neurais Artificiais

No processo de identificação em questão, o objetivo é avaliar o comportamento dinâmico de um processo não linear. A identificação pode ser definida como o “conhecimento” da relação entre as entradas e saídas do processo. Neste processo, os

<sup>1</sup> Escrito por: Marcelo Castier, Programa de Engenharia Química – COPPE, Universidade Federal do Rio de Janeiro. BASED ON A *SKELLETION* OF THE ROUTINE TMSSJ OF M.L. MICHELSEN. (Instituttet for Kemiteknik - DTH - Denmark). 1990.

<sup>2</sup> Edgar, T. F. and Himmelblau, D. M. Optimization of Chemical Processes, p. 206-208, McGraw-Hill Intl.Ed., New York (1988).

valores deverão ser normalizados antes de serem apresentados à rede, com o objetivo de evitar que valores de ordem de grandeza distinta influenciem nos resultados. A expressão adotada para normalização resulta num padrão limitado entre 0,10 e 0,90, ao invés de 0,0 e 1,0. A escolha dessa normalização tem como objetivo possibilitar uma pequena extrapolação dos valores e evitar a utilização de valores extremos (DE SOUZA JR., 1993; SANTOS, 2000). A expressão de normalização dos padrões adotada foi:

$$V_{nor} = 0,10 + \left( \frac{V_{real} - V_{min}}{V_{max} - V_{min}} \right) \times 0,80 \quad (3.19)$$

para desnormalização dos padrões, foi utilizada a expressão inversa:

$$V_{real} = V_{min} + \frac{(V_{nor} - 0,10)}{0,80} \times (V_{max} - V_{min}) \quad (3.20)$$

onde:  $V_{nor}$  é o valor normalizado

$V_{min}$ : valor mínimo assumido pela variável;

$V_{max}$ : valor máximo assumido pela variável;

$V_{real}$ : valor da variável nas unidades do processo.

Quatro classes de modelos são sugeridas para identificação em processos não lineares, os quais podem ser descritos por equações de diferenças finitas (NARENDRA & PARTHASARATHY, 1990; LANDAU, 1979 *apud* JAGANNATHAN & LEWIS, 1996). São eles:

Modelo I: 
$$y(k+1) = \sum_{i=0}^{n-1} \alpha_i y(k-i) + f[u(k), u(k-1), \dots, u(k-m+1)] + d(k). \quad (3.21)$$

$$\text{Modelo II: } y(k+1) = \sum_{i=0}^{m-1} \beta_i u(k-i) + f[y(k), y(k-1), \dots, y(k-n+1) + d(k)]. \quad (3.22)$$

$$\text{Modelo III: } y(k+1) = f[y(k), y(k-1), \dots, y(k-n+1)] + g[u(k), u(k-1), \dots, u(k-m+1) + d(k)]. \quad (3.23)$$

$$\text{Modelo IV: } y(k+1) = f[y(k), y(k-1), \dots, y(k-n+1); u(k), u(k-1), \dots, u(k-m+1) + d(k)]. \quad (3.24)$$

onde  $f(\cdot) \in R^n$  e  $g(\cdot) \in R^n$  são funções não lineares,  $m$  e  $n$ , estão relacionados a ordem do sistema. As variáveis  $u(k)$  e  $y(k)$  representam respectivamente, a entrada e a saída de um processo no tempo de amostragem  $k$ , e  $d(k) \in R^n$  representa o vetor distúrbio no instante  $k$ . O Modelo IV é o mais geral, e também conseqüentemente, o de maior dificuldade de implementação. Os Modelos I e II são casos especiais de IV, quando a saída do processo é linear nos valores passados de  $y$  e  $u$ , o que pode não ser aceitável para o caso do modelo utilizando a unidade de FCC. No Modelo III, considera-se que os efeitos na saída dos valores passados de  $y$  e  $u$  são separáveis e aditivos. Neste trabalho será suposto que o processo da FCC tem a estrutura dada pelo Modelo IV. Portanto, para a identificação via RNA, a relação entre as entradas ( $y(k), \dots, y(k-n+1); u(k), \dots, u(k-m+1)$ ) e a saída da rede neural ( $\hat{y}(k+1)$ ), representando um sistema discreto no tempo, será descrita por:

$$\hat{y}(k+1) = \hat{f}[y(k), y(k-1), \dots, y(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad (3.25)$$

Na etapa de treinamento, os pesos e *bias* da rede serão ajustados, de modo a minimizar o erro, definido como erro de identificação, fornecido pela diferença entre o valor predito e o valor desejado para a variável  $y$ , ou seja,

$$e(k+1) = \hat{y}(k+1) - y(k+1) \quad (3.26)$$

O esforço computacional será tanto menor, quanto menor for a ordem do sistema,

ou seja, o valor de  $m = n$ , conforme pode ser observado na Figura 3.8 onde está exemplificado para um sistema SISO (SANTOS, 2000b). Para  $n = m = 1$  e  $n = m = 2$ , com  $H$  representando o número de neurônios na camada escondida a estrutura possui  $3 \times H + 2$  conexões e  $5 \times H + 2$  conexões, respectivamente. Fazendo esta mesma análise para o caso proposto, considerando agora que teremos 4 variáveis controladas e 4 variáveis manipuladas, o número de parâmetros a ser estimado seria  $13 \times H + 4$  conexões, para  $n = m = 1$ , e  $21 \times H + 4$  conexões, para  $n = m = 2$ . Com isto este último caso possui  $1,6 \times H$  parâmetros a mais a serem estimados, correspondendo a 319 conexões para 15 nós na camada intermediária.

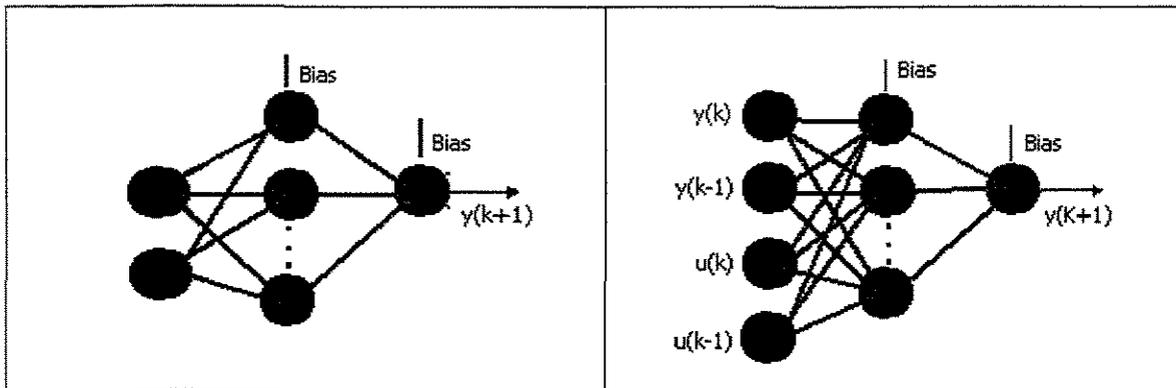


Figura 3.8 Estrutura das RNA para  $n = m = 1$  à esquerda e para  $n = m = 2$  à direita para um sistema SISO (SANTOS, 2000b).

O comportamento dinâmico do modelo não linear pode ser capturado por redes recorrentes, onde os neurônios são interligados para frente e para trás arbitrariamente envolvendo um sistema de equações diferenciais ordinárias não lineares e exigindo alto custo computacional (tempo); ou então este comportamento pode ser capturado alimentando os valores passados de saída do processo, juntamente com os valores presentes na forma de um modelo NARX (*Non-linear Auto-Regressive eXogenous*) (BHAT & McAVOY, 1992). No sistema proposto o comportamento dinâmico do processo será obtido apresentando os padrões na forma de variações no tempo, sendo considerado de ordem igual a 1; então diz-se que o comportamento dinâmico será capturado por uma rede neural não dinâmica. Desta forma, apenas os valores presentes serão apresentados à rede, não sendo fornecidos os valores dos instantes anteriores. Os dois métodos passíveis de serem usados para a identificação de um processo são denominados normalmente de método

série-paralelo (MPS) e método paralelo (MP). No método *backpropagation* de treinamento os sinais para trás (redes recorrentes) não estão presentes. De modo que permite apenas o treinamento no esquema série-paralelo (SANTOS, 2000). O método MPS será adotado neste estudo (NARENDRA & PARTHASARATHY, 1990 *apud* JAGANNATHAN & LEWIS, 1996; LIMA & OLIVEIRA, 1997). A Figura 3.9 ilustra estes dois métodos.

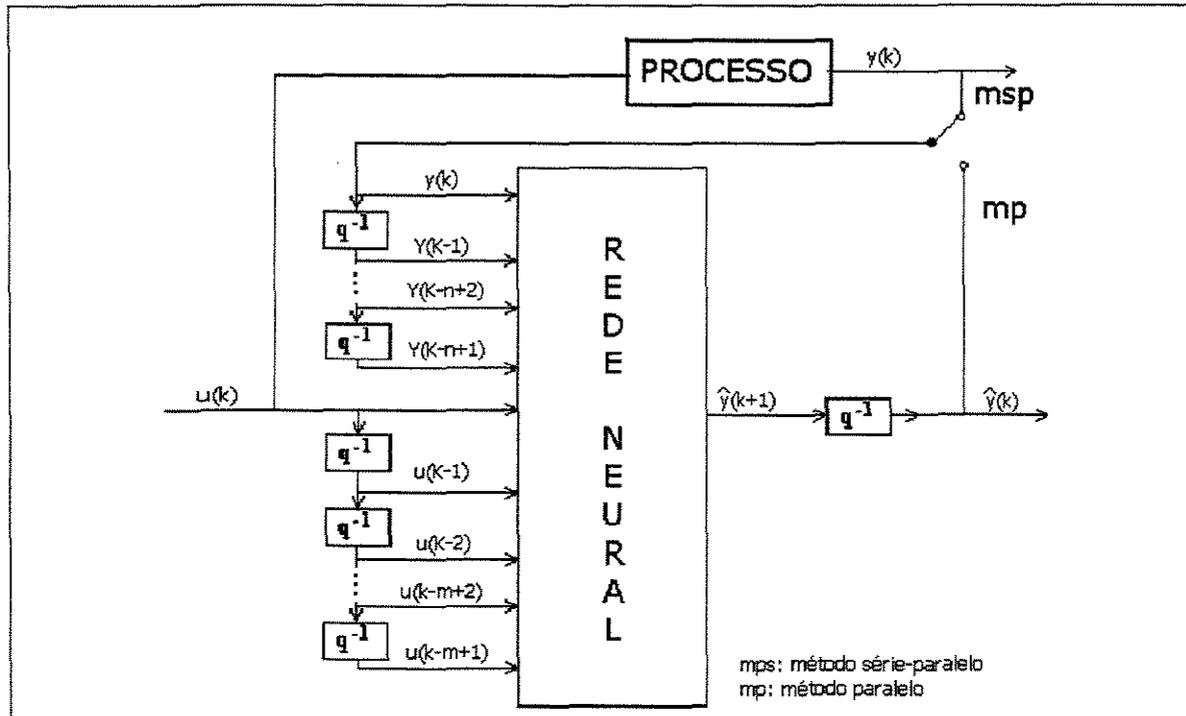


Figura 3.9 Opções de identificação do processo utilizando rede neural para capturar o comportamento dinâmico; método série-paralelo e método paralelo.

No método série-paralelo, a saída do processo é alimentada na rede neural, e no método paralelo, as saídas atrasadas da própria rede são alimentadas à mesma. A Equação 3.25, referente ao Modelo IV, passa a ser escrita na forma:

$$\hat{y}(k+1) = \hat{f}[\hat{y}(k), \hat{y}(k-1), \dots, \hat{y}(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad (3.27)$$

Esta forma de se reproduzir o comportamento dinâmico, usando formas não lineares de equações de diferenças finitas, requer um número bem maior de entradas na rede, o que obviamente requer mais neurônios e pesos a serem ajustados, porém, o

treinamento é relativamente mais simples do que no caso de sistemas de equações diferenciais não lineares.

### 3.4 Aplicação das redes neurais no FCC

Neste item é feita uma descrição do processo de identificação da unidade de FCC em redes neurais. De acordo com a descrição do item 3.2.2 *Estratégia de controle do FCC*, para esta unidade várias estratégias de controle poderiam ser apresentadas. O objetivo aqui não foi o de propor uma mudança nas condições de controle, nem alterar as ações das variáveis manipuladas e controladas da unidade, mas sim de propor uma alternativa de controle utilizando RNA. Procurou-se manter as mesmas considerações de restrição e controle operacional existentes nesta unidade, inserindo se necessário uma rotina de otimização baseada nesta estratégia já existente. Para o processo de identificação em redes neurais as seguintes variáveis operacionais foram selecionadas como variáveis controladas:

- Temperatura da Fase Densa do Primeiro Estágio de Regeneração – TRG1;
- Temperatura da Fase Densa do Segundo Estágio de Regeneração – TRG2;
- Severidade da Reação Catalítica – SEV;
- Temperatura na Saída do *Riser* – TRX.

As temperaturas apresentam restrições relativas a limitação de material, segurança e estabilidade do próprio processo catalítico. As temperaturas das fases densas do primeiro e segundo estágios de regeneração são controladas a partir da injeção de ar no regenerador. Na verdade este controle representa um controle indireto, pois a variável que se deseja controlar é a temperatura da fase diluída geral. Esta temperatura é a melhor indicação da conversão do regenerador para controlar a razão CO/CO<sub>2</sub>, na ausência de um analisador de linha. Para manter esta temperatura nos limites especificados, na faixa de 705 a 720°C, as temperaturas das fases densas deverão ser mantidas próximas aos seus valores de referência para controle, ou seja, 671,6°C no primeiro estágio e 700,8°C no segundo. Como a razão entre as vazões de ar para o primeiro e segundo estágios é mantida fixa ( $RAI1/RAI2=10$ ) conforme modelo fenomenológico, torna-se difícil manter as duas variáveis nos seus respectivos valores de referência ao mesmo tempo para todos os estados estacionários. Desta forma, se uma delas for controlada, por exemplo, a variável TRG1, a outra não necessariamente será mantida exatamente no controle. Esta limitação é observada quando

se executa o programa de simulação da unidade FCC, dessa forma é esperado o mesmo comportamento no modelo em redes neurais.

A Temperatura de Saída do *Riser* é considerada a variável mais importante para ajuste da conversão do reator sendo usada para definir estratégias de produção. Um valor elevado nesta temperatura aumenta a produção de hidrocarbonetos leves, sendo adequado para aumentar a produção de GLP; por outro lado, um valor mais baixo aumenta a produção de Nafta, que constitui a principal meta de uma unidade de FCC. Temperaturas excessivamente altas tendem a formar muito gás combustível, o que limita a produção da unidade devido a limitações no processamento deste gás, e um valor muito baixo irá limitar a conversão da unidade. Para maximizar a conversão de Nafta, esta variável deve ser mantida próximo de 542°C, e para elevar a produção de GLP a temperatura deve ser mantida em 545°C.

A Severidade da Reação Catalítica representa na verdade um valor estimativo, obtido empiricamente (Equações D.6 e D.6a ANEXO D). Para produção de Nafta, este valor deve ser mantido próximo de 76,7%. Seu controle pode ser feito alterando-se a temperatura do reator, ou a temperatura da carga. É importante observar a estreita relação entre a temperatura de saída do *Riser* e a severidade da reação catalítica, de forma que alterando-se o valor de referência de uma, necessariamente irá afetar o valor da outra. Da mesma forma como ocorre nas temperaturas do regenerador, é esperado também um comportamento similar entre as variáveis severidade da reação catalítica e temperatura de saída do *Riser* no modelo em redes neurais. Portanto, para se obter uma resposta adequada de controle, faz-se necessário alterar ambos valores de referência. Esta variável apresentou restrições de máximo em 85% e de mínimo em 70%.

Além dessas variáveis, outras ainda necessitam ser mantidas dentro de uma faixa restrita de controle. É o caso das variáveis associadas do processo. Pertencem a este grupo de variáveis o diferencial de pressão entre regenerador e reator - SETPDCV, que permite um fluxo contínuo de catalisador escoando do regenerador para o reator, sendo mantido em 0,65kgf/cm<sup>2</sup> e a temperatura da fase diluída geral - TDG, que indica a conversão do regenerador, sendo mantida entre 710 e 725°C.

É sabido que estes valores de referência podem apresentar ligeiras variações em função principalmente da qualidade da carga. Considera-se, entretanto, que mantendo estas

variáveis selecionadas dentro de um certo limite de controle, a unidade FCC será mantida em condições estáveis de operação, mantendo a conversão constante mesmo na presença de perturbações externas como, por exemplo, as mudanças na qualidade da carga ou as oscilações inerentes ao processo.

Foi efetuado um teste de sensibilidade da unidade. Neste procedimento procurou-se aplicar degraus em algumas variáveis, denominadas aqui de variáveis manipuladas, acompanhando-se suas influências nas variáveis controladas e associadas em função do tempo, utilizando o sistema aberto, ou seja, sem ação de controle. Os testes de simulação realizados consistiram de variações em forma de degraus nas variáveis:

- Vazão de Alimentação – RTF;
- Temperatura da Alimentação – TFP;
- Vazão de Ar para o Regenerador – RAI;
- Abertura da Válvula de Catalisador Regenerado – CTCV.

Estas variáveis manipuladas também apresentam restrições de operação. A variável RTF - vazão de alimentação, por exemplo, é controlada por outro algoritmo externo à unidade, então a estratégia normalmente efetuada nesta variável é manter os valores de máximo e mínimo de restrição próximos um do outro, em uma situação previamente definida fora da unidade. Caso se deseja efetuar uma estratégia de otimização de produção nesta variável, seus limites de restrição poderão ser alterados, sendo aumentados ou diminuídos, conforme a operação decida por elevar ou reduzir a produção. Os limites existentes para esta variável são:  $383,3\text{m}^3/\text{h}$  a  $416,7\text{m}^3/\text{h}$ . A variável TFP - temperatura de alimentação, representa uma variável importante para ajuste da severidade da reação catalítica atuando no controlador de temperatura do forno de carga. Apresenta apenas limite mínimo de  $219^\circ\text{C}$ . A variável RAI - vazão de ar para o regenerador, é utilizada para controlar a temperatura dos leitos densos. Convém observar que esta vazão representa a vazão total de ar para o regenerador, conforme já dito. Esta variável apresenta um limite máximo de  $240\text{kNm}^3/\text{h}$ . A variável CTCV - abertura da válvula de catalisador regenerado, apresenta uma resposta muito acentuada (maior sensibilidade) nas variáveis SEV e TRX. Apresenta restrição de máximo em 0,9 unidades e de mínimo em 0,72 unidades.

Uma vez definidos os controles propostos, ou seja, definidas as variáveis controladas e as variáveis manipuladas, é apresentado a seguir a estrutura da rede neural que irá representar a unidade de FCC.

Devido a complexidade da estrutura da rede neural proposta foram consideradas duas estratégias de identificação para representar o modelo. Na primeira estratégia, com o objetivo apenas de obtenção dos parâmetros de treinamento da rede, como, por exemplo, a obtenção do número de padrões, o número de degraus mínimo necessário para cada variável manipulada, a frequência de amostragem e a precisão de convergência (representada pelo gradiente da função objetivo) foi considerado um sistema MIMO mais simples. Neste sistema MIMO cada variável manipulada foi tratada individualmente, sendo geradas uma rede neural para cada variável manipulada, resultando em 4 redes neurais. Na segunda estratégia foi considerado um sistema MIMO mais complexo, onde as variáveis manipuladas foram tratadas em conjunto. Nesta estratégia de identificação foram usados os parâmetros obtidos das 4 redes obtidas pela estratégia anterior.

No sistema MIMO mais simples, o número de nós na camada de entrada da RNA foi definido como sendo igual ao número de variáveis controladas, obtidas no instante atual ' $k$ ' adicionado de uma variável manipulada, obtida também no instante atual ' $k$ ', ou seja, a rede foi representada por cinco (5) nós. Estes nós na camada de entrada corresponderam a:  $TRG1_k$ ,  $TRG2_k$ ,  $SEV_k$  e  $TRX_k$ ; adicionado de uma das seguintes variáveis:  $RAI_k$ ,  $CTCV_k$ ,  $RTF_k$  ou  $TFP_k$ . No sistema MIMO mais complexo o número de nós na camada de entrada da RNA foi definido como sendo igual ao número de variáveis controladas, obtidas no instante atual ' $k$ ' adicionado de todas as variáveis manipuladas também no instante atual ' $k$ ', ou seja, a rede foi representada por oito (8) nós. Estes nós, portanto, corresponderam a:  $TRG1_k$ ,  $TRG2_k$ ,  $SEV_k$ ,  $TRX_k$ ,  $RAI_k$ ,  $CTCV_k$ ,  $RTF_k$  e  $TFP_k$ . O número de nós na camada de saída foi definido como igual ao número de variáveis controladas, obtidas no instante futuro  $k+1$ , sendo representada por quatro (4) nós tanto no sistema MIMO mais simples quanto no sistema mais complexo, correspondendo a:  $TRG1_{k+1}$ ,  $TRG2_{k+1}$ ,  $SEV_{k+1}$  e  $TRX_{k+1}$ . Na ausência de um critério preciso para determinação do número de nós na camada intermediária, foi adotado para esta determinação o método de tentativa e erro. A determinação desses parâmetros no sistema MIMO mais simples, como intervalo de tempo entre cada degrau e intensidade destes degraus, para cada variável manipulada, obedeceu a

uma certa lógica baseada em tentativa e erro associada a “bom senso”, uma vez que existe um certo compromisso entre o tempo de treinamento, a precisão da rede neural e a necessidade de extrapolação desses resultados para serem utilizados no sistema MIMO mais complexo. A Figura 3.10 mostra a arquitetura 8x15x4 proposta para a rede neural que irá representar o modelo fenomenológico (sistema MIMO mais complexo). Nesta figura não estão representados os pesos e *bias* por limitação de espaço na mesma.

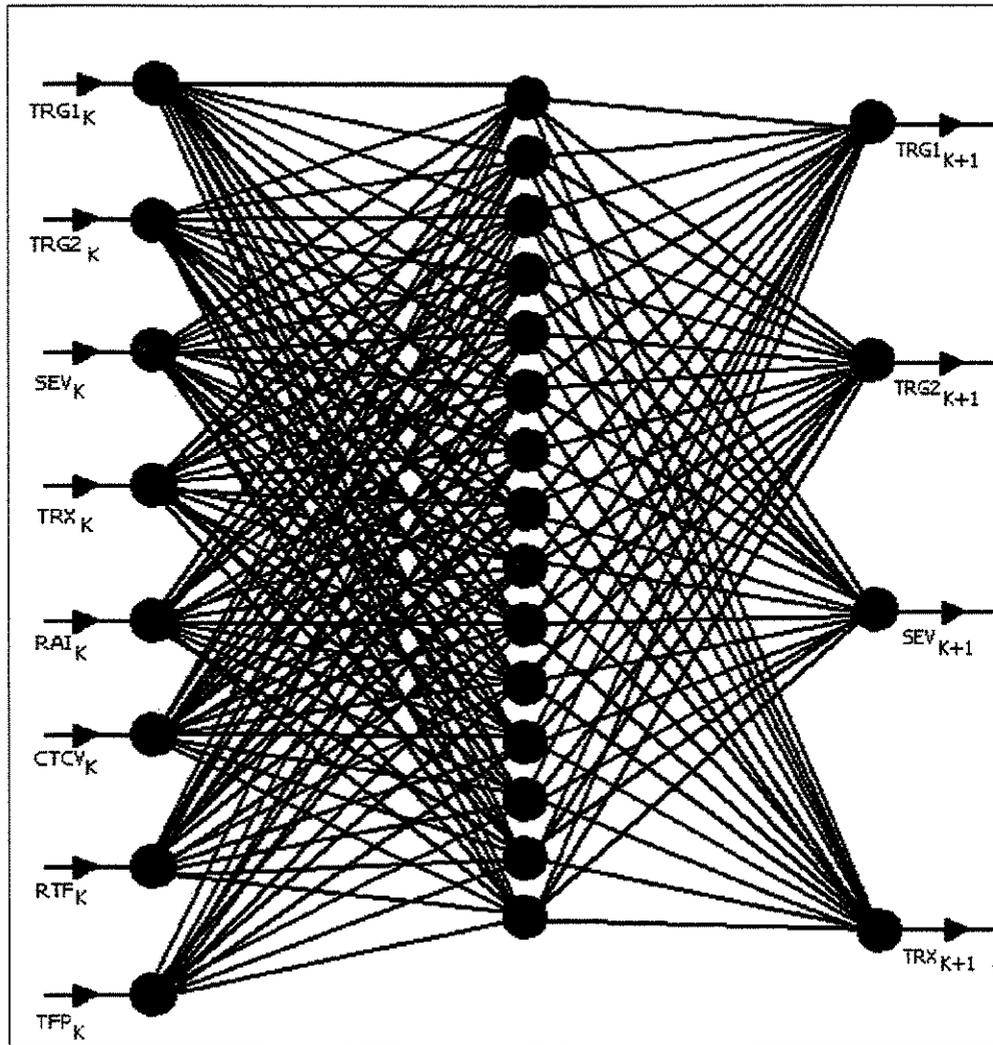


Figura 3.10 Esboço da representação da rede neural proposta com arquitetura 8x15x4, referente ao sistema MIMO mais complexo. Os pesos e *Bias* não estão apresentados por problemas de limitação de espaço na figura.

O algoritmo de identificação do processo em redes neurais artificiais (vide ANEXO E) descreve passo a passo o procedimento utilizado na obtenção do modelo em

redes neurais. Foram utilizadas rotinas computacionais em linguagem FORTRAN para realização deste procedimento.

### 3.5 Controle Preditivo com Modelo

Neste estudo é proposto utilizar o Controle Preditivo com Modelo devido à sua grande capacidade de projeto de sistemas de controle, com obtenção de ótimo desempenho e capacidade de operação por grandes períodos de tempo sem intervenções freqüentes de especialistas (FILETI, 1998). Sua aplicação é bastante adequada para sistemas multivariáveis e com restrições. O controle preditivo apresenta algumas variações, *Model Algorithmic Control – MAC*, *Dynamic Matrix Control – DMC*; *Generalized Predictive Control – GPC*; *Receding Horizon Control – RHC* e *Neural Network Internal Model Control – NNIMC*. Cada uma dessas variações se fundamenta em metodologias ligeiramente distintas apresentando vantagens e limitações.

O controle preditivo é assim denominado devido à forma como é feito o cálculo da lei de controle, ou seja, no instante atual, chamado instante  $k$  é feita a previsão do processo para instantes futuros,  $k+1$ ,  $k+2$ , ...,  $k+N_p$ , onde  $N_p$  é denominado horizonte de predição. O ponto de partida para esta predição é representado pelos sinais das variáveis controladas e manipuladas atuais provenientes da unidade industrial. A partir de um modelo, previamente definido, são feitas previsões das respostas do processo simulando alterações nas variáveis manipuladas para  $N_c$  instantes futuros, onde  $N_c$  representa o horizonte de controle; normalmente  $N_c \leq N_p$ . São feitas então seleções destas variáveis de forma a escolher aquelas que fornecem somente respostas com determinadas características. Apesar da previsão ser feita sobre um horizonte de controle, apenas a primeira predição é implementada na ação do controlador. Após implementação, o tempo é atualizado para  $k+1$  e todo o cálculo é repetido. A Figura 3.11 apresenta o esboço da ação do controle preditivo para um sistema SISO genérico qualquer.

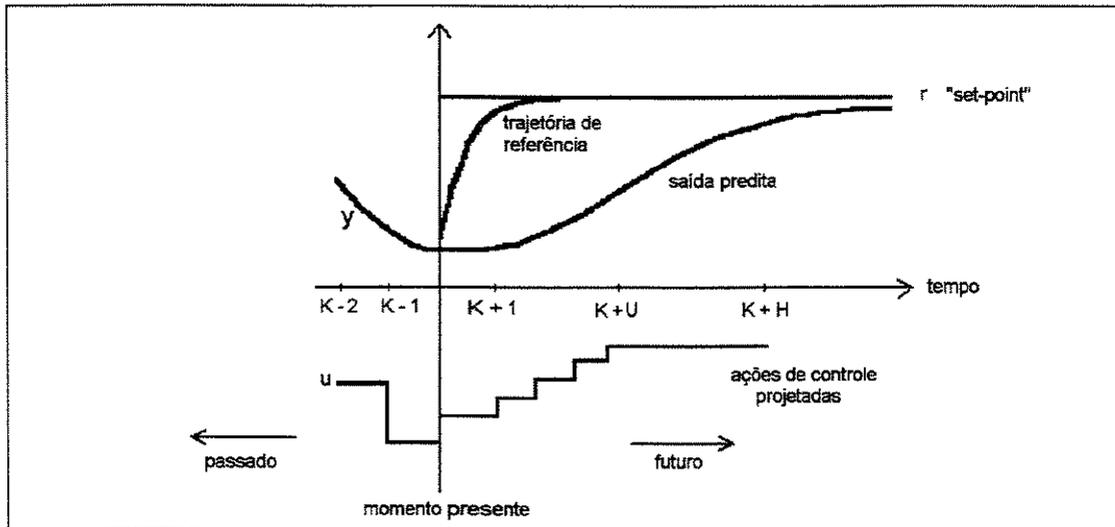


Figura 3.11 Esboço ilustrativo da ação de controle preditivo considerando apenas uma variável controlada (sistema SISO).

Normalmente, adota-se um critério de comparação entre a resposta predita e a resposta desejada para escolha da ação do controlador. Esta comparação é feita por meio de minimização de equações algébricas que geralmente são funções da variável controlada predita –  $\hat{y}$ , da variável manipulada –  $u$  e de uma trajetória de referência –  $sp$  (*setpoint*). Desta forma, o erro futuro é minimizado, e se o modelo escolhido representar bem o processo e se não ocorrerem distúrbios, o processo seguirá fielmente a trajetória de referência. Existem três técnicas diferentes para se representar o modelo interno de predição, como Modelo de Convolução, utilizado no Controle por Matriz Dinâmica, Modelos Heurísticos, utilizados no Controle por Modelo Algoritmo, e Modelo por Redes Neurais, utilizados no Controle por Rede Dinâmica. No presente estudo é proposto utilizar as Redes Neurais Artificiais, para representar o modelo de predição.

### 3.5.1 Controle do FCC utilizando como modelo as Redes Neurais

A metodologia de Controle Preditivo com Modelo pode utilizar como modelo do processo a própria rede neural. Frequentemente leva em consideração apenas os dados de entrada e saída sem necessidade do conhecimento prévio das leis fundamentais que regem o processo. Alguns autores denominam uma variação dessa técnica de Controle por Rede Dinâmica – DNC (Willis *et al.*, 1992, *apud* FILETI, 1998). Esta técnica relativamente recente foi aplicada pelos autores na simulação de um sistema não linear caracterizado por eles de sistema de múltiplas entradas e única saída (*Multiple Input and Single Output* –

*MISO*), representado por uma coluna piloto de 10 estágios. A rede proposta apresentou arquitetura do tipo 3-4-4-1 ( $I \times H1 \times H2 \times O$ ) para simular um controle preditivo não linear, sendo comparado com um modelo preditivo linear com tempo morto e com um controlador PI (Proporcional Integral). Foi utilizado o mesmo horizonte de predição e controle para ambos os controladores. Analisando o erro pelo método Integral do Erro Absoluto IAE (*Integral Absolute Error*), foi observado que o controle preditivo não linear apresentou o menor índice IAE. Eles implementaram também o mesmo controlador preditivo não linear para demonstrar sua aplicabilidade em um problema com características MIMO.

O diagrama a seguir (Figura 3.12) mostra um esquema de um controlador preditivo utilizando Redes Neurais (BHAT & McAVOY, 1990; *apud* DE SOUZA JR., 1993).

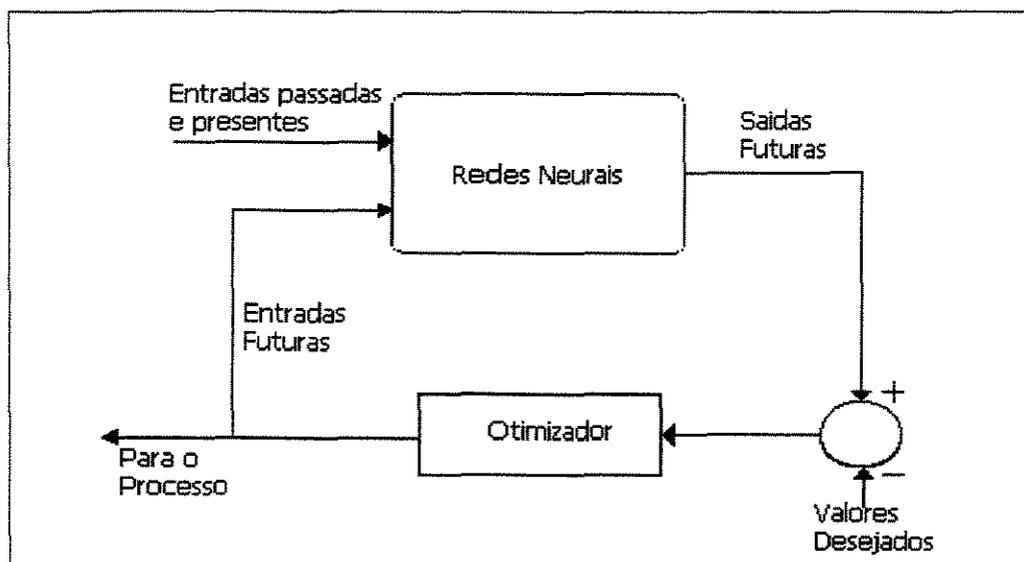


Figura 3.12 Esquema genérico proposto para um Controlador Preditivo com Modelo utilizando Redes Neurais Artificiais (DE SOUZA JR., 1993).

A rede neural usada foi previamente treinada para identificação do processo. Para em seguida estar apta para o controle fazendo previsões um passo adiante, em um total de  $N_p$  previsões no futuro.

O método sugerido foi fundamentado numa proposta de WILLIS *et al.* (1992) e HUNT *et al.* (1992), (*apud* FILET, 1998), e se baseia na minimização de uma função objetivo  $j$  definida como,

$$j = \sum_{i=1}^{N_p} \alpha_q (\hat{y}_q(k+i) - sp_q(k+i))^2 + \sum_{i=0}^{N_c} \lambda_r (u_r(k+i) - u_r(k+i-1))^2 \quad (3.28)$$

onde  $N_p$  é o horizonte de predição,  $N_c$  é o horizonte de controle,  $\lambda$  são os pesos utilizados para penalizar variações excessivas da variável manipulada, e  $\alpha$  são os pesos de igual importância utilizados para se definir uma ordem de importância nas variáveis controladas, os índices  $q$  representa a variável controlada, e  $r$  representa a variável manipulada, (FILETI, 1998). A expressão da função objetivo  $j$  está sujeita as seguintes restrições nas entradas e saídas do processo:

$$y_{min} \leq \hat{y}_q(k+i) \leq y_{max}, i = 1, \dots, N_p \quad (3.29)$$

$$u_{min} \leq u(k+i) \leq u_{max}, i = 1, \dots, N_c \quad (3.30)$$

$$[u(k+i) - u(k+i-1)] \leq \Delta u_{max}, i = 1, \dots, N_c \quad (3.31)$$

A trajetória de referência para a estratégia de controle é dada pelo modelo:

$$sp_q(k) = y(k) \quad (3.32)$$

$$sp_q(k+i) = \beta sp_q(k+i-1) + (1-\beta) sp_q(k) \quad (3.33)$$

onde  $\beta$  assumiu os seguintes valores: 0,80; 0,85; 0,90; 0,95 e 0,97, dependendo do ajuste do controlador.

Para garantir a robustez do modelo, cada predição de um passo adiante da rede neural foi corrigida usando uma variável de correção fornecida por:

$$corr(k) = y(k) - \hat{y}(k | k-1) \quad (3.34)$$

A predição corrigida assume a forma:

$$\hat{y}_c(k+1|k) = \hat{y}(k+1|k) + corr(k) \quad (3.35)$$

onde  $y(k)$  é a saída real do processo no tempo de amostragem  $k$ ,  $\hat{y}(k|k-1)$ , é a predição da variável  $y$  para o instante  $k$  obtida pela rede neural no tempo de amostragem anterior  $(k-1)$  e  $\hat{y}_c(k|k+1)$  é a variável corrigida.

A rotina computacional do controlador foi desenvolvida utilizando a linguagem FORTRAN®, sendo inserida na rotina do modelo fenomenológico. As restrições já existentes neste modelo fenomenológico foram mantidas, e as rotinas de entrada e saída de dados foram aproveitadas. O processo de minimização da função objetivo foi realizada empregando a rotina *NCONF*, da biblioteca *IMSL*, interna do FORTRAN. Esta rotina implementa o método de programação quadrática sucessiva (*Successive Quadratic Programming – SQP*) e o método do gradiente por diferenças finitas (*Finite Difference Gradient*), mas não está disponível na forma aberta, e portanto não se tem acesso aos programas fontes. No ANEXO C é apresentado um algoritmo para implementação do Controlador Preditivo com Modelo via Redes Neurais Artificiais. No programa em linguagem FORTRAN, foram incluídas as restrições do modelo (Equações 3.29 a 3.31), sendo estas restrições utilizadas também para realizar a estratégia de otimização do controlador. As variáveis manipuladas e controladas deverão primeiro ser normalizadas nos mesmos moldes da normalização usada no processo de identificação, (Equações 3.19 e 3.20), antes de serem inseridas como dados de entrada do programa.

Após identificação do modelo em RNA, ou seja, após obtenção da rede neural e após desenvolvimento do modelo preditivo usando esta rede neural como modelo para predição do comportamento do sistema MIMO mais complexo, foram feitos testes de simulação para verificar o desempenho dos resultados do modelo proposto. A Figura 3.13 a seguir apresenta um esboço do sistema de controle proposto, já acoplado ao sistema convencional. Convém lembrar que a unidade FCC é representada por um simulador matemático denominado de modelo fenomenológico.

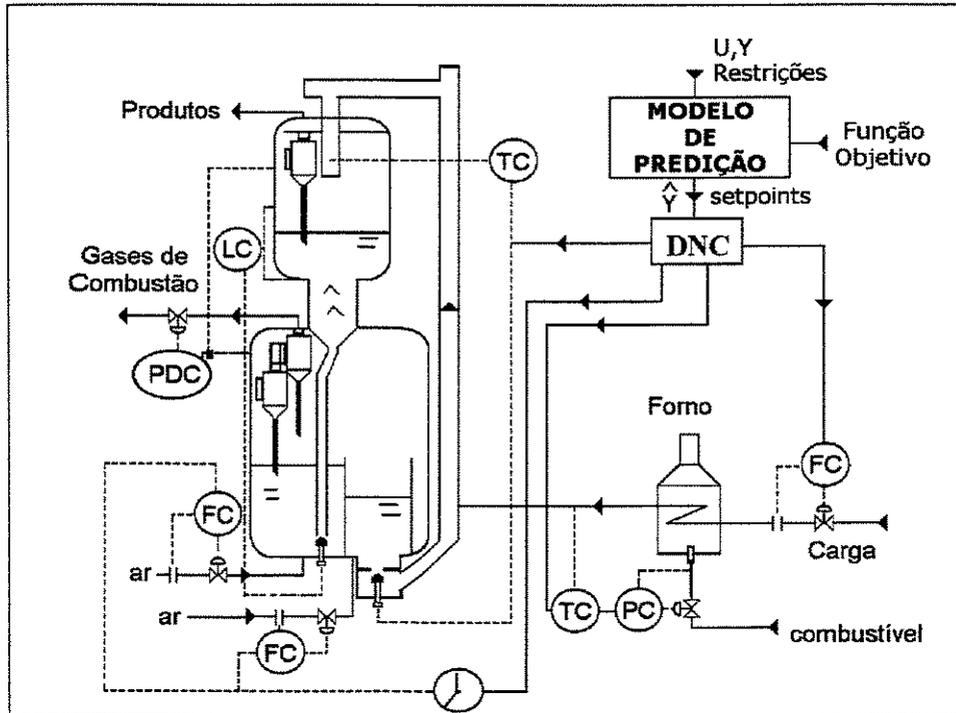


Figura 3.13 Esboço do sistema de controle proposto, via Redes Neurais Artificiais, para acoplamento ao controle convencional da unidade FCC.

## CAPÍTULO IV

### RESULTADOS

É proposto otimizar o controle da unidade FCC, representada aqui por um modelo fenomenológico existente, procurando manter as variáveis do processo dentro de seus limites de restrição frente às perturbações no sistema, quer sejam na vazão, temperatura ou qualidade da carga. A estratégia definida para esta proposta foi primeiramente realizar a identificação do processo da FCC em RNA, gerando um modelo. Posteriormente foi desenvolvido um controlador preditivo que fez uso do modelo desenvolvido em RNA como modelo interno do controlador. Com o controlador proposto acoplado ao simulador que é o próprio modelo fenomenológico foram realizados diversos testes de desempenho, comparando seus resultados com o sistema aberto e com o modelo DMC obtido por MORO, (1992). Seguem os resultados obtidos da identificação, controle e testes efetuados.

#### **4.1 Identificação do modelo fenomenológico via Redes Neurais Artificiais**

##### ***4.1.1 Obtenção dos conjuntos de dados a partir do modelo fenomenológico***

Diversas variáveis operacionais poderiam ser utilizadas como variáveis controladas e manipuladas na indústria (vide CAPÍTULO III). Porém, a alteração da estratégia básica de controle existente atualmente na unidade FCC não fez parte deste estudo, portanto as mesmas variáveis controladas e manipuladas consideradas no estudo de MORO foram também consideradas neste estudo. A estratégia de produção proposta foi a de maximizar a produção de Nafta sendo entretanto realizado um teste propondo mudança de produção para GLP, visando avaliar o desempenho do controlador num processo de alteração da estratégia de produção. Como o modelo fenomenológico desenvolvido por Moro foi usado para representar a unidade industrial no processo de identificação em RNA, procurou-se elevar ao máximo a amplitude dos degraus nas variáveis manipuladas, para avaliar a capacidade das Redes Neurais Artificiais em fornecer as respostas adequadas nas variáveis controladas sem ultrapassar os limites de restrição de cada uma delas.

Partindo de um programa em linguagem FORTRAN, denominado aqui de modelo fenomenológico, desenvolvido por MORO (1992), o qual representa a dinâmica da unidade FCC, foram obtidos por simulação diversos conjuntos de dados em malha aberta, isto é,

sem ação de controle, para diferentes condições de operação. Para isto foram implementados degraus nas 4 variáveis manipuladas individualmente, RAI, CTCV, RTF e TFP, partindo de um estado estacionário inicial, observando-se o seus efeitos nas 4 variáveis controladas, TRG1, TRG2, SEV e TRX, e nas variáveis associadas TDG e TD2 em função do tempo.

Estes dados obtidos da simulação foram divididos em três grupos: conjunto de dados para treinamento da rede neural – *grupo de treinamento*, conjunto de dados para validação do modelo – *grupo de validação*, e conjunto de dados para teste da rede neural já treinada – *grupo de teste*. O método da validação cruzada foi usado para obtenção dos dados para treinamento da rede (padrões de treinamento e validação). Obviamente, a forma como foram obtidos os grupos de treinamento e validação garante que o grupo de dados de treinamento é também um subconjunto do grupo de validação, mas o grupo de dados de teste foi obtido utilizando outra seqüência de degraus de forma a não comprometer a validade da rede neural. Posteriormente, os arquivos obtidos de cada um dos grupos eram normalizados e armazenados na forma adequada para serem lidos pelo programa de redes neurais. Foi a partir destes conjuntos que a identificação do modelo da FCC em redes neurais foi realizada.

#### ***4.1.2 Obtenção das condições do treinamento das redes***

Utilizando um simulador de redes neurais, conforme CAPÍTULO III e procedimentos descritos no ANEXO E, foram criadas diversas arquiteturas de redes neurais, sendo treinadas, validadas e testadas pelos vários conjuntos de dados obtidos do modelo fenomenológico.

Inicialmente, foram feitas simulações em um sistema MIMO mais simples, utilizando apenas uma variável manipulada, observando as respostas nas quatro variáveis controladas, visando obter o número de degraus em cada variável manipulada; o valor de cada degrau; o intervalo de tempo entre dois degraus consecutivos, que pudessem abranger toda a faixa de operação da variável; a freqüência de amostragem; e o gradiente da função objetivo (que é um dos critérios de convergência da rede neural, e que define indiretamente a precisão do resultado da rede). Este sistema MIMO foi gerado apenas para esta finalidade.

Diversas arquiteturas de RNA foram obtidas, sendo considerado como aceitas para análise aquelas configurações cujos resultados das variáveis controladas obtidos das redes

neurais apresentaram erros relativos inferiores a 1% em todos os pontos, quando comparados com os resultados obtidos com o modelo fenomenológico. Desta forma, a estratégia de criação das redes neurais obedeceu a uma rotina de cálculos rigorosamente estabelecida (vide ANEXO E). Estes resultados obtidos utilizando este sistema MIMO mais simples foram úteis para uma estimativa da configuração do modelo utilizando um sistema MIMO mais complexo, onde estava previsto utilizar as quatro variáveis manipuladas em uma única rede neural.

A Tabela 4.1 apresenta alguns resultados obtidos do treinamento da rede na etapa de determinação dos parâmetros para configuração da rede neural, utilizando processador Pentium II 400 MHz. O programa era sempre reiniciado com pesos e *bias* diferentes quando a convergência não era atingida. Isto era observado quando o programa travava por algum motivo ou quando o valor mínimo do gradiente da função objetivo não era encontrado.

Tabela 4.1 Exemplos de alguns resultados de arquiteturas de RNA obtidos para determinação dos parâmetros da rede: número de degraus, número de padrões de treinamento e precisão do gradiente.

Arquite- tura da rede (1)	Variável manipu- lada	nº degraus	Número de padrões	Tempo de CPU (minuto)	Gradiente (critério de convergência)	Função objetivo	Nº iterações	Obs:
8x15x4	(2)	25	1367	2589	5,26E-4	1,09E-1	861	
5x3x4	RAI	6	584	107	6,02E-8	2,10E-2	2528	(5)
5x9x4	TFP	6	284	17	8,20E-4	4,45E-1	200	
5x20x4	TFP	6	284	238	9,41E-4	4,28E-1	213	
5x5x4	RTF	23	892	3307	(1,00E-9)	-	-	(3) (4)
5x6x4	RTF	23	892	920	8,11E-8	1,34E-2	6845	(3)
8x3x4	(2)	30	2091	97	3,54E-4	6,22E-1	1203	(5)
5x5x4	CTCV	7	434	355	9,45E-8	2,61E-2	>10000	(6)
5x4x4	CTCV	8	343	126	9,02E-8	1,40E-2	8320	(6)
5x6x4	RAI	13	928	-	(1,00E-7)	-	-	(3) (7)
5x7x4	RTF	23	892	9161	(1,00E-9)	-	-	(3) (4)

(1) Camadas de entrada, escondida e de saída da rede neural (*I x H x O*): (*Input, Hidden, Output layers*).

(2) RAI, TFP, RTF e CTCV;

(3) Número excessivo de padrões para esta arquitetura de rede e esta precisão (critério de convergência);

(4) O programa não convergiu mesmo após reiniciar 8 vezes utilizando valores de pesos diferentes;

(5) Resultados não satisfatórios com 3 nós na camada escondida (com perda de generalidade);

(6) O programa convergiu após reiniciar 3 vezes com pesos aleatórios diferentes;

(7) O programa não convergiu.

Inicialmente, com a utilização de um processador Pentium 100 MHz, não foi obtido sucesso na convergência para nenhuma configuração de rede neural com mais de 5 nós na primeira camada, utilizando um número superior a 2500 padrões no treinamento da

rede e adotando como critério de convergência um valor inferior a  $1,0e-7$  no gradiente da função objetivo. Uma vez que haveria necessidade de modelar o sistema com as 4 variáveis manipuladas juntas, representativo do sistema MIMO mais complexo, foram necessários alguns ajustes nos parâmetros da RNA na obtenção do grupo de treinamento, como a redução do número de padrões, a alteração do tempo de amostragem e a diminuição da precisão da rede, na tentativa de se reduzir o tempo de treinamento e avaliar a condição limite de cada um desses parâmetro. Esta exigência foi justificada pela elevada carga computacional do método do gradiente conjugado utilizado no programa de treinamento via *backpropagation*.

Na ausência de um critério para a determinação dos parâmetros a serem utilizados na configuração da RNA, considerou-se como ponto de partida os mesmos valores de degraus recomendados por MORO, (1992). Devido à necessidade de abranger toda a faixa de restrição das variáveis manipuladas, esta escolha resultou em um número excessivo de degraus no treinamento, ou seja, 23 degraus na variável RTF, 13 degraus na variável RAI e 18 degraus na variável TFP; a amostragem, para esses casos foi tomada de 2 em 2 minutos e o tempo considerado entre dois degraus consecutivos foi de 200 minutos, constante para todas as variáveis (por facilidade de programação). Desta forma, alguns problemas surgiram, como por exemplo, a obtenção de um número de padrões excessivo, 4600 padrões apenas para a variável RTF. Outro problema encontrado foi que em algumas das simulações efetuadas, o sistema não chegava a atingir o estado estacionário antes da implementação do degrau seguinte, observado quando se aplica degraus nas variáveis manipuladas RAI e CTCV, pois para essas variáveis, as variáveis controladas necessitam de um intervalo de tempo acima de 200 minutos para atingir o novo estado estacionário.

Posteriormente, foi tentado reduzir o número de degraus em cada variável manipulada e, simultaneamente, aumentar o intervalo de tempo entre os degraus. Obviamente, reduzir o número de degraus implica em aumentar a amplitude do mesmo. Assim, outros problemas surgiram, pois um degrau maior resulta em respostas mais agressivas tanto nas variáveis controladas quanto nas variáveis associadas do processo, resultando em temperaturas que ultrapassavam os limites impostos pela restrição do modelo.

Foi observado que a simulação no modelo fenomenológico, para obtenção dos grupos de dados da identificação, deveria apresentar um compromisso entre o número de

degraus e o intervalo de tempo entre eles, de forma a abranger toda a faixa de operação da variável manipulada, sem no entanto sobrecarregar o processamento computacional do treinamento das redes neurais. Outra exigência necessária, relativa ao treinamento, foi reduzir de forma acentuada o número de padrões a ser apresentado à rede neural, reduzindo a frequência de amostragem; inicialmente tomado amostras de 2 em 2 minutos, passando para de 4 em 4 minutos e finalmente para a frequência de 6 em 6 minutos. Observou-se que um valor acima deste último compromete os resultados da rede neural, e os valores inferiores à frequência de 6 minutos provou-se serem excessivos do ponto de vista do processo, além de comprometer o tempo de treinamento.

A frequência de amostragem dos dados utilizados para validação (grupo de validação) não apresentou nenhuma restrição quanto ao tempo de processamento, obtendo respostas num intervalo de alguns segundos, sendo portanto adotada a frequência de 2 em 2 minutos para validação das RNA. Com isto, o número de padrões na etapa de validação das redes foi 3 vezes superior ao número de padrões de treinamento [(6 em 6) x (2 em 2 min.)].

O gradiente da função objetivo, que indica a precisão alcançada pela rede durante o treinamento, também precisou ser alterado, pois foi observado que um valor muito baixo, da ordem de  $1,00e-7$  ou inferior, dependendo do número de padrões apresentados à rede e da arquitetura proposta, resultava na não convergência do método. Observou-se também que a utilização de um valor mais elevado, da ordem de  $1,00e-2$  no gradiente da função objetivo, não necessariamente resultou numa rede mal condicionada como era esperado, mas, por outro lado, permitiu a convergência e tornou o processamento bem mais rápido. Portanto, depois de exaustivos testes com o sistema MIMO mais simples nas condições intermediárias entre  $1,00e-2$  e  $1,00e-7$ , adotou-se o valor de  $1,00e-3$  no gradiente da função objetivo como critério de convergência para o sistema MIMO mais complexo.

A Tabela 4.2 a seguir apresenta as variáveis manipuladas, com os valores obtidos após testes exaustivos de simulação. Dessa forma são apresentados os degraus, a frequência de amostragem e o tempo entre os degraus, selecionados para obtenção dos conjuntos de treinamento e de validação das RNA. Estes valores foram utilizados tanto no modelo fenomenológico quanto no modelo em redes neurais, testando cada uma variável manipulada individualmente. Observa-se que estes degraus nas variáveis manipuladas abrangem toda a faixa de operação da respectiva variável, sendo possível obter qualquer estado estacionário dentro do intervalo de validade do modelo fenomenológico.

Tabela 4.2 Variáveis manipuladas, suas respectivas perturbações impostas, frequência de amostragem e intervalo de tempo entre cada degrau para os conjuntos de treinamento e os conjuntos de validação das RNA, nas configurações 1 e 2.

VARIÁVEIS MANIPULADAS	CONJUNTO DE TREINAMENTO E VALIDAÇÃO													
	Degrau (%)						Tempo entre degraus (min.)							
	Configuração 1:			5xHx4			(MIMO mais simples).							
<b>TFP</b>	-5,	-8.5,	-3,	+1,	+4,	0	270,	300,	300,	300,	300,	300		
<b>RAI</b>	-5,	-9,	-3,	+1,	+4,	0	570,	600,	900,	600,	600,	300		
<b>RTF</b>	-6,	-10,	-4,	+2,	+7,	0	270,	300,	300,	300,	300,	300		
<b>CTCV</b>	-7,	-12,	-5,	+2,	+11,	+4,	0	270,	300,	300,	300,	600,	600,	300
	Configuração 2:			8xHx4			(MIMO mais complexo).							
<b>TFP;</b>	-5,	-8.5,	-3,	+1,	+4,	0,	300,	300,	300,	300,	300,	300,		
<b>RAI;</b>	-5,	-9,	-3,	+1,	+4,	0,	600,	600,	900,	600,	600,	300,		
<b>RTF;</b>	-6,	-10,	-4,	+2,	+7,	0,	300,	300,	300,	300,	300,	300,		
<b>CTCV</b>	-7,	-12,	-5,	+2,	+11,	+4,	0	270,	300,	300,	300,	600,	600,	300
	Frequência de amostragem						Treinamento: de 6 em 6 minutos							
							Validação: de 2 em 2 minutos							

As arquiteturas representadas pela estrutura geral  $5xHx4$  ( $IxHxO$ ) representam o sistema MIMO mais simples e as arquiteturas representadas por  $8xHx4$  representam o sistema MIMO mais complexo; variando o valor de  $H$ , número de neurônios na camada intermediária, as diversas configurações das redes neurais puderam ser obtidas. No sistema MIMO mais simples, os 5 nós na camada de entrada representam as seguintes variáveis: uma variável manipulada e quatro variáveis controladas, relativas ao instante atual  $k$ , e a camada de saída é formada pelas 4 variáveis controladas relativas ao instante futuro  $k+1$ . Os números de nós representativos da camada intermediária foram determinados de forma sistemática, iniciando por 2 nós e aumentando até 20 nós. Dos modelos obtidos em redes neurais, foi escolhido para representar a unidade de FCC um dos que apresentaram melhor desempenho associado ao menor tempo de treinamento.

A frequência de amostragem dos dados utilizados para teste da rede (grupo de teste) não apresentou nenhuma restrição quanto ao tempo de processamento, obtendo respostas num intervalo de alguns segundos, sendo portanto adotada a frequência de 1 em 1 minuto para teste das RNA. O grupo de teste das redes treinadas apresentou um número de padrões diferentes do número de padrões apresentado pelo grupo de treinamento para cada variável manipulada testada. Estes padrões foram distribuídos em 3 degraus.

A Tabela 4.3 apresenta os resultados obtidos após exaustivos testes de simulação dos valores dos degraus, a frequência e o tempo de amostragem, selecionados para obtenção do conjunto de teste das redes neurais artificiais. Conforme se pode observar, os

valores dos degraus aqui obtidos foram diferentes daqueles utilizados para treinamento e validação das redes neurais. A configuração 1 corresponde ao sistema MIMO mais simples e a configuração 2 corresponde ao sistema MIMO mais complexo.

Tabela 4.3 Variáveis manipuladas, suas respectivas perturbações impostas, frequência e tempo de amostragem para o conjunto de teste das redes neurais, nas configurações 1 e 2.

VARIÁVEIS MANIPULADAS	CONJUNTO DE TESTE		
	Degrau (%)		Tempo (min.)
<b>Configuração 1: 5xHx4 (MIMO mais simples)</b>			
TFP	+2.5, -2.5, 0		320, 350, 350
RAI	+2.5, -2.5, 0		320, 350, 350
RTF	+1.5, -1.5, 0		320, 350, 350
CTCV	+2.5, -2.5, 0		320, 350, 350
<b>Configuração 2: 8xHx4 (MIMO mais complexo)</b>			
TFP;	+2.5, 2.5, 0,		320, 350, 350,
RAI;	+2.5, -2.5, 0,		350, 350, 350,
RTF;	+1.5, -1.5, 0,		350, 350, 350,
CTCV	+2.5, -2.5, 0		350, 350, 350
Frequência de amostragem		Teste: de 1 em 1 minuto	

#### 4.1.3 Modelo escolhido em rede neural para representar o processo de FCC

Após testes exaustivos utilizando a configuração 1 da Tabela 4.2, a Rede Neural Artificial na configuração 8x15x4 foi escolhida para representar a unidade FCC. As características dessa rede neural escolhida podem ser observadas na Tabela 4.4. Conforme observado nesta tabela, a amostragem efetuada pelo simulador na etapa do treinamento foi de 6 em 6 minutos, utilizando 1367 padrões de treinamento. Para obtenção dos valores de pesos e *bias* utilizando essa arquitetura, o tempo de CPU na etapa de treinamento foi de 2589 minutos, e o tempo de CPU da etapa de validação da rede treinada foi de frações do minuto, apesar do número de padrões nesta etapa ser 3 vezes maior para amostragem de 2 em 2 minutos.

Tabela 4.4 Característica da rede neural que irá representar a unidade FCC como modelo interno do controle preditivo.

Arquitetura	Função objetivo	Gradiente da função objetivo	Amostragem (min.)			Número de padrões	
			Treinamento	Validação	Teste	Treinamento	Teste
8x15x4	1,090e-1	5,261e-4	6 em 6	2 em 2	1 em 1	1367	4058

A Tabela 4.5 a seguir estão mostrados os 207 valores de pesos e *bias* obtidos do treinamento da rede neural utilizando arquitetura 8x15x4.

Tabela 4.5 Valores obtidos de Pesos e *Bias* da Rede Neural com arquitetura 8x15x4, obtidos a partir de 1367 padrões de treinamento, considerando um valor de  $5,261e-4$  no gradiente da função objetivo e amostragem de 6 em 6 minutos.

.47642007E-01	-.10997058E+01	.53712952E+00	.16278169E+01	-.26623461E+01	.40162145E+01	-.85293986E+00
-.83308695E+00	.62985414E+00	-.19376488E+01	-.28953329E+01	.51304134E+00	-.20140789E+01	.95963696E+00
.44126629E+00	-.61118937E+00	-.23777494E+00	-.84760394E+00	-.92440208E+00	.16982143E+01	-.11754802E+01
.26943251E+01	.38326266E-01	-.16456690E+01	-.10112937E+01	.58967543E-01	-.99977825E+00	-.83331993E+00
.30860234E+00	.16321434E-01	-.10190787E+01	.91446274E+00	-.31826450E+01	-.42154347E+01	-.13748242E+01
-.12511031E+01	.47372795E+01	.72462004E+00	.25942670E+01	.38451975E+01	.33209471E+01	-.15924532E+01
.96389314E+00	.73748590E+01	.25633198E+00	.22942283E+00	-.17544575E+01	-.19177279E+01	.10782848E+01
.26172835E+00	.55785923E+00	.27624180E+01	-.65433978E+00	.90384369E+00	-.75437757E+00	-.11517354E+01
-.18234982E+01	-.10731542E+01	-.81131642E+00	.16132017E+00	-.52848359E+00	-.15770797E+01	.15695846E+00
.36307808E+01	-.39848365E+01	.37645591E+01	-.25552819E+00	-.19227990E+00	.10948989E+01	-.21864137E+01
-.49544216E+01	.94621508E+00	-.27028238E+01	-.16543556E+01	-.46811181E+01	.35281410E+00	-.28959553E+01
-.32984398E+00	.24791173E+01	-.32945610E+01	.37290757E+01	.30380304E+00	-.16222274E+01	.46884296E+00
-.22939766E+01	-.31556919E+01	-.71339962E+00	-.34056904E+01	-.78899875E+00	-.46898667E+01	-.78531621E+00
-.20056079E+01	.67539046E+00	.35037244E+01	.12661227E+01	.21081713E+01	.79291829E-01	-.14226274E+01
-.61056905E+01	-.34389588E+01	-.32125939E+01	-.19469285E+01	-.21447461E+01	-.48438877E+01	.33765429E+01
-.13541679E+01	-.34852518E+01	-.42514642E+00	.35225725E+01	.28535996E+00	.40107947E+01	-.11296984E+01
-.25676889E+01	-.46521538E+01	-.27902707E+01	-.34609998E+01	-.94447819E+00	-.32538245E+01	-.72755567E+01
.68332677E+00	-.48739794E+01	-.55139962E+01	-.41175465E+01	-.61297857E+01	.22214469E+01	.16640388E+01
.24202851E+01	.12922740E+01	-.22921244E+01	-.24820667E+01	-.12754215E+01	-.21005135E+01	.27903429E+01
.15251891E+01	.35602338E+01	.41070880E+01	-.34680382E+01	-.52021135E+01	.49014304E+00	-.17908792E+01
.33645843E+01	.41807872E+01	-.31221733E+00	.17187288E+01	.35363162E+01	.28532667E+01	.37259543E+01
.35348205E+01	-.18540924E+01	-.18538534E+01	-.31026818E+01	-.38375686E+01	-.41504812E+00	-.10013938E+01
-.73990152E+01	-.32039620E+01	-.34465615E+00	-.17125642E-02	-.16057288E+01	-.20700661E+01	.24284576E+01
.17967249E+01	.22928926E+01	.16208579E+01	-.65611859E+00	-.18173554E+00	-.63848331E+00	-.44428257E+01
.33196312E+00	.32679148E+00	-.77376488E+00	.11445027E+00	-.48887102E+01	-.42656076E+01	-.71196779E+01
-.75145752E+01	-.56249613E+01	-.58074619E+01	.95778501E+00	-.96698590E-01	.00000000E+00	.00000000E+00
.00000000E+00	.00000000E+00	.00000000E+00	.00000000E+00	.00000000E+00	.00000000E+00	.12526530E+01
-.51555794E+00	-.25060151E+01	-.39141717E+01	.26143436E+01	-.77652453E+00	.45172553E+01	.18567980E+01
.18321523E+01	.18599109E+01	.56379407E+00	.28302349E+01	.68566420E+00	.74563115E+01	.32621059E+01
.67111958E+00	.15943810E+01	.17271837E+01	.14709207E+01			

Estes valores de pesos e *bias* encontrados na etapa de treinamento serão os mesmos utilizados na etapa de validação e teste da rede. Os gráficos das Figuras 4.1 a 4.4 representam os resultados obtidos da validação da rede neural, observados os critérios de treinamento e validação da Tabela 4.2, comparados com os resultados obtidos do modelo fenomenológico obtidos com a configuração 8x15x4. Nos gráficos das Figuras 4.5 e 4.6 são mostrados os degraus impostos em cada uma das variáveis manipuladas e os intervalos de tempo entre estes mesmos degraus (obtido conforme a Tabela 4.2), aplicados no modelo fenomenológico e no modelo em RNA com a arquitetura 8x15x4 escolhida. Conforme se pode observar desses gráficos a estratégia adotada para as perturbações foi a de aplicar diversos degraus em cada uma das variáveis manipuladas individualmente, procurando

abranger toda a faixa de operação dessas variáveis, enquanto as demais variáveis eram mantidas fixas em um estado estacionário.

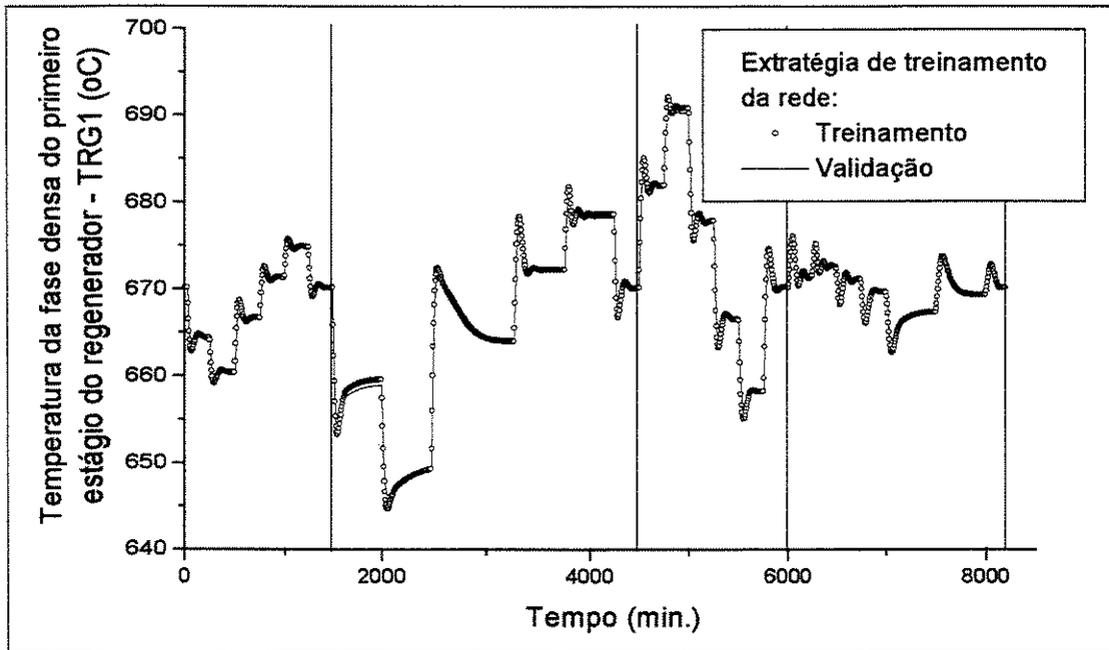


Figura 4.1 Resposta na Temperatura da Fase Densa do primeiro estágio do regenerador, TRG1, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura 8x15x4 na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua).

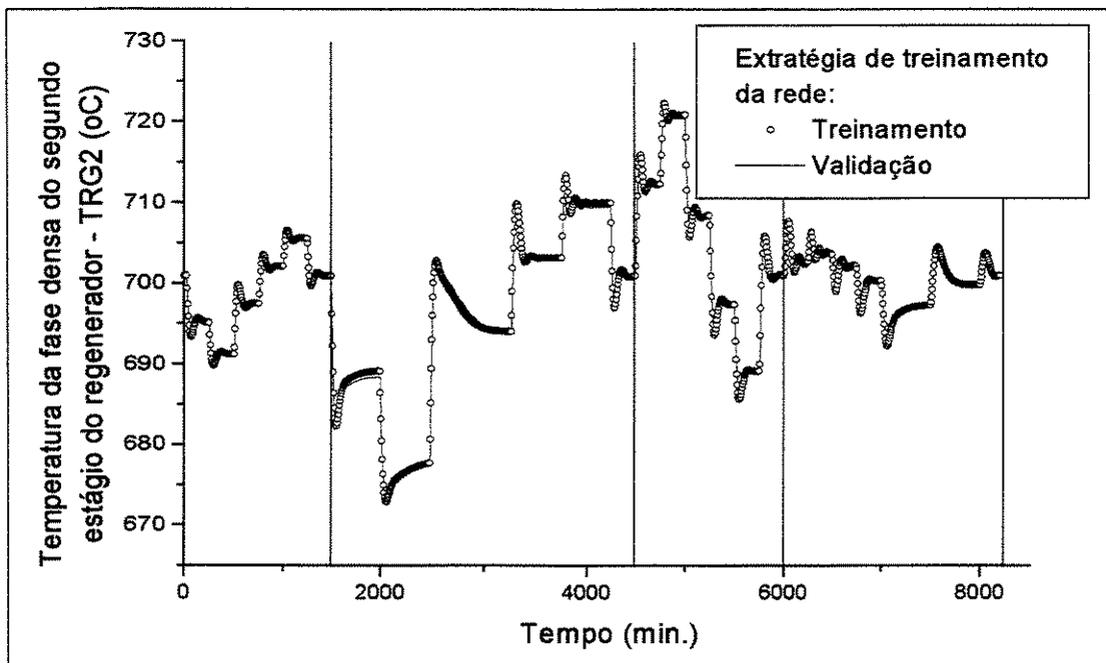


Figura 4.2 Resposta na Temperatura da Fase Densa do segundo estágio do regenerador, TRG2, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura 8x15x4 na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontínua).

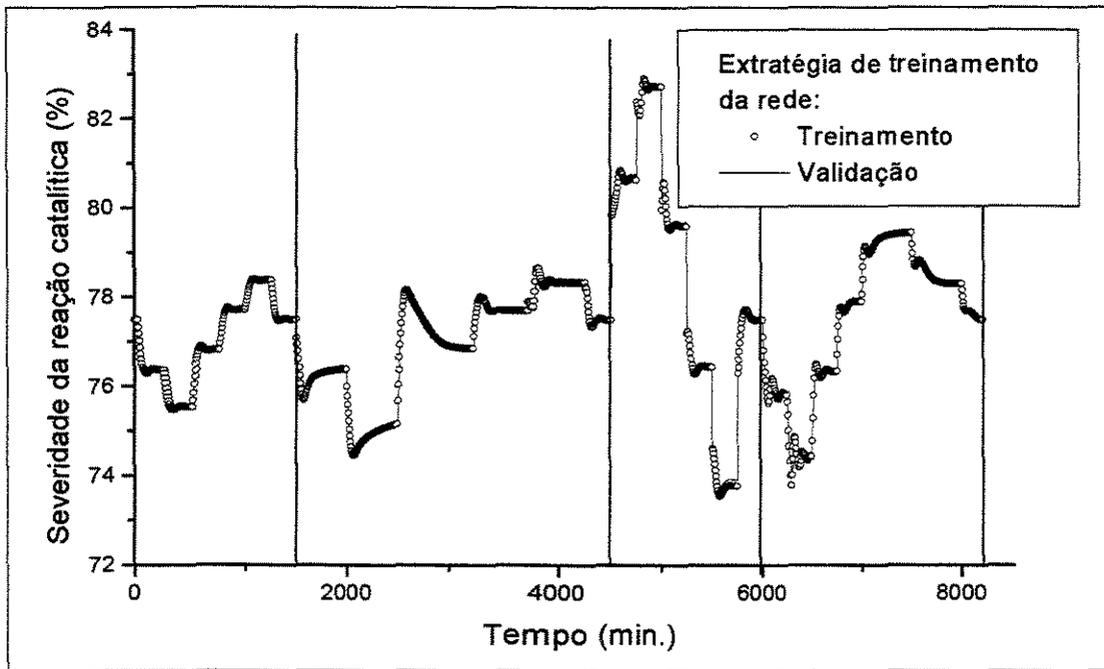


Figura 4.3 Resposta na Severidade da Reação Catalítica, variável SEV, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura 8x15x4 na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontinua).

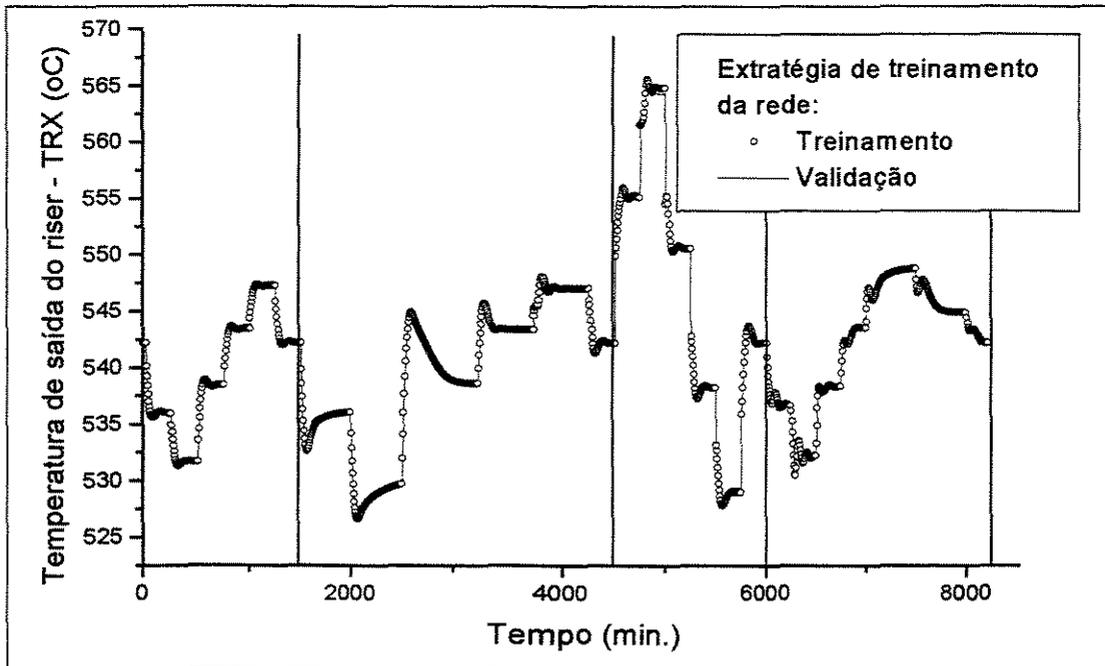


Figura 4.4 Resposta na Temperatura de Saída do Riser, TRX, aos degraus impostos nas variáveis manipuladas, TFP, RAI, RTF e CTCV, com arquitetura 8x15x4 na RNA. Comparação entre RNA (representação em linha contínua) e modelo fenomenológico (representação descontinua).

Cada gráfico das Figuras 4.1 a 4.4 representa a resposta obtida de cada uma variável controlada aos degraus impostos nas variáveis manipuladas. Neles, as linhas

verticais nos instantes 1500, 4500, 6000 e 8200 minutos, delimitam os intervalos correspondentes aos degraus aplicados em cada variável manipulada, ou seja, delimitam a ação das variáveis TFP, RAI, RTF e CTCV, respectivamente, conforme pode ser observado nas Figuras 4.5 e 4.6. Conforme se observa, o tempo necessário para as variáveis controladas atingirem um novo estado estacionário após cada degrau é diferente para cada variável manipulada. Também pode ser observado que uma mesma variável controlada pode apresentar comportamentos diferentes em diferentes estados estacionários, uma característica da não linearidade do processo. Nestes gráficos, a indicação representada por um círculo corresponde aos valores do modelo fenomenológico apresentados para treinamento da rede e a indicação representada por uma linha contínua corresponde aos resultados de validação da rede. O erro relativo percentual apresentado na etapa de validação entre os resultados da rede e do modelo foi inferior a 0,3% em todos os pontos tanto nas variáveis controladas quanto nas associadas do processo.

A boa concordância entre os valores de treinamento e de validação observada em todos os gráficos das Figuras 4.1 a 4.4 é um indicativo de que a rede neural na configuração escolhida, arquitetura 8x15x4, representa bem o modelo fenomenológico. Durante o processo de identificação, ficou evidente que as redes neurais com arquiteturas formadas por um número de nós na camada intermediária superior a 15, como por exemplo a rede com arquitetura 8x20x4, também poderia representar o processo de FCC, mas além de apresentar um tempo de processamento de CPU mais elevado, os resultados obtidos não apresentaram nenhuma melhora significativa que justificassem o uso desta configuração.

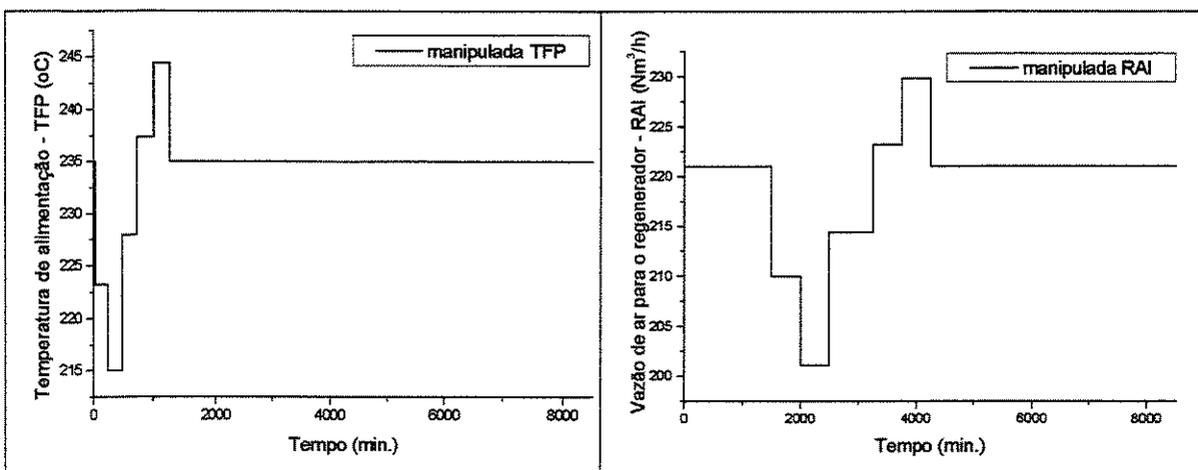


Figura 4.5 Degraus impostos nas variáveis manipuladas: Temperatura da Alimentação do Reator, TFP (esquerda), e Vazão de Ar para o Regenerador, RAI (direita), nas etapas de treinamento e validação da rede neural, na configuração 8x15x4 (vide Tabela 4.2).

Os gráficos da Figura 4.5 mostram as variações impostas às variáveis temperatura da carga - TFP e vazão de ar - RAI; 6 degraus na variável TFP, e, posteriormente, 6 degraus na variável RAI, de forma a abranger toda a faixa de variação permitida pelas restrições do modelo fenomenológico para estas variáveis, ou seja, de 215°C a 245°C, e de 201kNm<sup>3</sup>/h a 231kNm<sup>3</sup>/h, respectivamente.

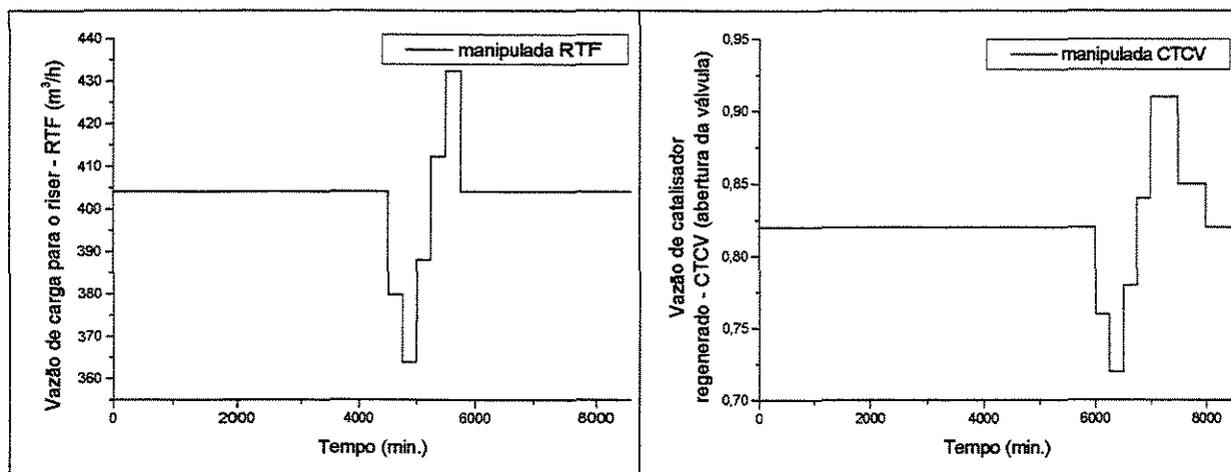


Figura 4.6 Degraus impostos na variável manipulada: Vazão de Alimentação do Reator, RTF (esquerda) e Vazão de Catalisador Regenerado, CTCV (direita), nas etapas de treinamento e validação da rede neural na configuração 8x15x4 (vide Tabela 4.2).

Os gráficos da Figura 4.6 mostram as variações impostas às variáveis vazão de carga - RTF e abertura da válvula de catalisador regenerado - CTCV; foram aplicados 6 degraus na variável RTF e posteriormente 7 degraus na variável CTCV, abrangendo toda a faixa de controle adotada, de 363m<sup>3</sup>/h a 416,7m<sup>3</sup>/h, para a variável RTF, e de 0,72 a 0,92 para a variável CTCV. Foi a partir desses degraus nas variáveis manipuladas que as respostas nas variáveis controladas TRG1, TRG2, SEV e TRX (Figuras 4.1 a 4.4) puderam ser obtidas.

Os gráficos das Figuras 4.7 e 4.8 mostram uma comparação em forma de dispersão entre os resultados obtidos utilizando o modelo fenomenológico (também chamado aqui de modelo rigoroso) e os resultados obtidos utilizando a configuração escolhida da rede neural 8x15x4, utilizando outro grupo de dados (padrões de teste), diferentes das seqüências de treinamento e de validação (vide Tabela 4.3). O objetivo da utilização de um conjunto de dados para teste contendo seqüência de degraus diferentes da seqüência de treinamento e validação é verificar a capacidade de generalização da rede (BAUGHMAN & LIU, 1995).

Como os valores obtidos pelo simulador são não ruidosos e é sabido que a unidade industrial apresenta freqüentemente característica bastante ruidosa em seus sinais, foi proposta a inserção de um ruído na tentativa de simular de forma mais real os sinais provenientes da unidade. O ruído foi distribuído de forma aleatória, apresentando intensidade máxima de 1%, com freqüência também aleatória nas variáveis controladas proveniente do modelo fenomenológico. Os resultados obtidos dessa simulação são mostrados nos gráficos das Figuras 4.7 e 4.8 a seguir.

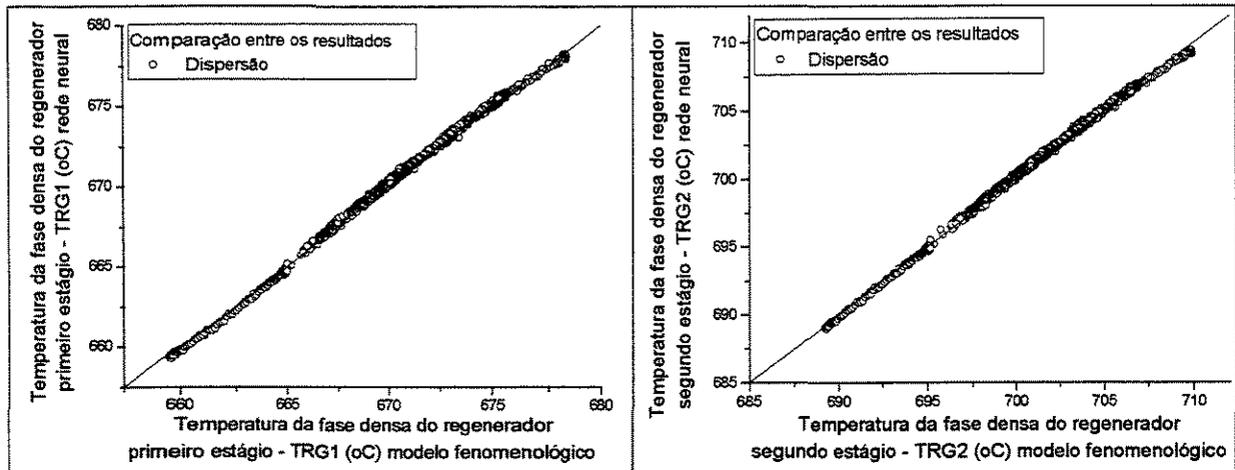


Figura 4.7 Comparação entre os resultados obtidos da variável TRG1 (esquerda) e TRG2 (direita), pelo modelo em redes neurais com ruído e os resultados obtidos pelo modelo rigoroso, aplicando degraus nas variáveis TFP, RAI, RTF e CTCV, conforme Tabela 4.3, configuração 2.

Conforme pode ser observado nos gráficos da Figura 4.7, que representam as temperaturas das fases densas do regenerador, as respostas entre modelo rigoroso, valores das abcissas, e simulação em rede neural, valores das ordenadas, foram praticamente coincidentes (a reta traçada a partir da bissetriz representa valores iguais da abcissa e da ordenada). O erro relativo percentual entre os valores da rede e os valores do modelo rigoroso com ruído foi inferior a 0,1% para todos os pontos do gráfico.

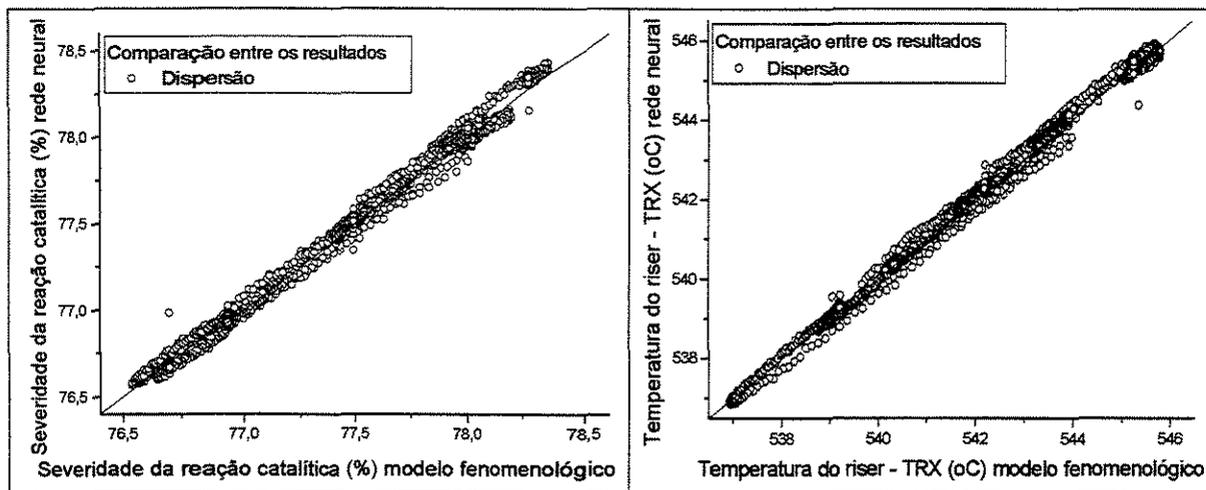


Figura 4.8 Comparação entre os resultados obtidos da variável severidade da reação catalítica (esquerda) e TRX (direita), pelo modelo em redes neurais com ruído e pelo modelo rigoroso, com os degraus impostos nas variáveis TFP, RAI, RTF e CTCV (vide Tabela 4.3, configuração 2).

Os gráficos da Figura 4.8, apesar de apresentarem maior dispersão se comparados com os gráficos da Figura 4.7, representaram erro relativo máximo inferior a 0,7% para variável severidade da reação catalítica (SEV) (esquerda) e inferior a 0,3% para a variável temperatura do *Riser* (TRX) (direita). Portanto, baseado nestes resultados, o modelo desenvolvido em RNA atende perfeitamente ao propósito de representar a unidade FCC num controle preditivo, apresentando boa capacidade de generalização e robustez.

#### 4.2 Controlador Preditivo usando as RNA como modelo interno

Uma vez escolhido o modelo em redes neurais que será usado para representar o processo de FCC, foi desenvolvido um controlador preditivo multivariável para o controle desta unidade, utilizando como modelo interno a rede neural na configuração escolhida.

Convém observar que mesmo a rede sendo treinada considerando a ação de degraus em cada variável manipulada individualmente conforme definido na estratégia de identificação, o controlador proposto, utilizando a técnica de minimização de uma função objetivo para um sistema multivariável, prevê a atuação do controlador em todas as variáveis manipuladas simultaneamente. Isto representa um procedimento ainda não aplicado em RNA para controle multivariável conforme constatado na literatura, e portanto caracteriza uma ação de controle inédita.

A ação do controlador desenvolvido pode ser realizada juntamente com estratégias de otimização da planta. Estas estratégias podem ser selecionadas por ação externa, onde se

determina qual variável será manipulada alterando os limites de restrição para aquela variável. Dentre as estratégias para o caso em questão que apresenta interesse, pode ser citada a otimização da produção, alterando os limites de restrição da variável vazão de carga - RTF, adequado quando há necessidade de maximizar ou minimizar a produção da unidade. Observou-se que a ação do controlador sobre esta variável, pode resultar numa estratégia não adequada aos interesses da refinaria como por exemplo, pode resultar em redução ou aumento não adequado de produção. Realmente, apesar de terem sido escolhidas 4 variáveis para serem usadas como variáveis manipuladas, na verdade a variável RTF, não deveria à princípio ser considerada como variável manipulada pois sua estratégia é definida normalmente por fatores externos à unidade de FCC (MORO, 1992). No entanto, ela é fundamental para otimização da planta quando se busca como objetivo a maximização de produção.

Outra estratégia também útil corresponde à otimização da ação de controle sobre a temperatura da carga, variável TFP. Caso haja alguma limitação no forno de carga o controlador pode limitar a faixa de ação nesta variável. Esta estratégia de ação do controlador pode ser estendida também para quaisquer outras variáveis manipuladas ou para as controladas (com algumas ressalvas), apenas alterando seus limites de restrição. Com relação às variáveis controladas, uma estratégia normalmente utilizada nas refinarias é a de se alterar o objetivo da unidade, passando a produzir mais GLP ao invés de Nafta, e isto pode ser feito alterando-se o valor de referência da variável TRX.

O mesmo programa do modelo fenomenológico usado para gerar os dados de treinamento (MORO, 1992) foi usado para simular a unidade industrial. A rotina do controlador foi inserida como uma subrotina no programa do modelo fenomenológico e as rotinas de entrada e saída de dados para impressão existentes no modelo foram aproveitadas para apresentação de resultados. Na simulação, a partir do modelo fenomenológico, foram obtidos os dados das variáveis controladas e manipuladas que são as entradas para o controle. De posse desses dados é chamada a rotina de otimização onde é feita a predição das ações de controle, utilizando a rede neural para prever a resposta dessas ações nas variáveis controladas em todo horizonte de predição. Os resultados dessas predições resultam nas ações do controlador, em todo horizonte de controle. Seleccionadas as ações que minimizam as diferenças entre as trajetórias de referência e as variáveis controladas no horizonte de controle, a primeira ação de controle nas variáveis manipuladas é então

enviada de volta ao programa do modelo fenomenológico gerando os dados de impressão de resultados; então o ciclo se repete.

Como teste do controlador utilizando redes neurais como modelo interno, foram simulados 1000 minutos de operação, com ação do controlador à partir do minuto 100 sendo inserido uma perturbação após 400 minutos.

O simulador (programa do modelo fenomenológico) se inicia em uma condição fora do estado estacionário, denominada de condição inicial de operação; portanto, após início da ação de controle, ou seja, após o instante 100 minutos, o controlador inicia uma tentativa de levar as variáveis controladas para o seus valores de referência. Isto justifica a alteração observada em alguns dos gráficos no intervalo entre 100 e 400 minutos, instante da perturbação.

Os degraus impostos nas variáveis escolhidas para perturbação apresentaram algumas limitações devido ao próprio modelo fenomenológico, que tiveram seus degraus limitados a valores bastante conservativos (MORO, 1992; MORO & ODLOAK, 1995).

Algumas dificuldades foram encontradas nos testes realizados conforme reportado a seguir:

- **dificuldades na frequência de amostragem do controlador:** este dado representa a frequência de chamada da rotina de controle. As frequências de 1 em 1 minuto, de 2 em 2 minutos, de 4 em 4 minutos, de 5 em 5 minutos, de 6 em 6 minutos, de 8 em 8 minutos e de 10 em 10 minutos foram testados em todas as simulações, sendo observado que acima da frequência de 6 minutos as respostas não eram satisfatórias para nenhuma situação. Utilizando um tempo de 1 em 1 minuto, mesma frequência de amostragem utilizada na simulação pelo modelo fenomenológico, as respostas do controlador apresentaram oscilações crescentes, divergindo e interrompendo a simulação. Foi tentado corrigir este comportamento alterando os ajustes do controlador, mas sem muito sucesso. A frequência de 2 em 2 minutos também apresentou oscilações, mas em menor intensidade. As frequências de amostragem que se apresentaram mais satisfatórias para o controlador foram de 4 em 4 minutos, de 5 em 5 minutos e de 6 em 6 minutos;
- **dificuldades no horizonte de predição:** foram testados diversos valores de  $N_p$  ( $N_p = 1, 2, 4, 5, 10, 12, 15, 18$  e  $20$ ), sendo escolhidos apenas aqueles que apresentaram

resultados significativos. Dentre as dificuldades encontradas no ajuste dessa variável, duas se destacaram: primeiro, foram observadas oscilações utilizando um valor de  $N_p = 1$ , sendo que neste caso, só era possível concluir a simulação (até 1000 minutos), reduzindo muito o valor do degrau na variável perturbação, o que não representa uma alternativa satisfatória. A segunda dificuldade foi a tentativa de elevar o valor de  $N_p$  para valores acima de 1, mantendo os mesmos ajustes do controlador. Observou-se que após cada alteração neste horizonte foi necessário alterar todos os demais parâmetros do controlador, como  $\lambda_i$ ,  $\alpha_i$ , frequência de amostragem, filtros e perturbações impostas. Provou-se que  $N_p$  é extremamente sensível a variações da frequência de amostragem. O máximo obtido para este horizonte foi de 20 amostragens considerando uma frequência de 5 em 5 minutos, o que representa uma previsão de 100 minutos; ainda assim, nem todos os testes apresentaram resultados satisfatórios para este horizonte. Valores muito baixo apresentaram oscilações nas respostas do controlador. Os valores de  $N_p$  que apresentaram melhores resultados foram 10, 12, 15 e 20 amostragens;

- **dificuldades no ajuste da variável filtro:** esta variável determina as trajetórias de referência das variáveis controladas. Os valores testados foram: 0,80, 0,90, 0,95, e 0,97; observou-se que estas variações exerciam alguma influência nos resultados do controlador. Procurou-se manter o mesmo valor de filtro para todas as variáveis controladas em cada teste, sendo os valores 0,90 e 0,97 os que apresentaram melhores resultados para a maioria das situações testadas;
- **dificuldades nos valores de ajuste de  $\lambda_i$  e  $\alpha_i$  no controlador:** essas variáveis,  $\lambda_i$  e  $\alpha_i$ , correspondem às punições aplicadas às variáveis manipuladas e controladas. Foi tentado, mas sem sucesso, implementar um mesmo ajuste para estas variáveis em todos os testes de perturbação efetuados. Os valores utilizados em cada situação estão reportados juntos aos dados dos testes, nas seções seguintes;
- **dificuldades no horizonte de controle:** para esta variável,  $N_c$ , a dificuldade encontrada foi na tentativa de elevar este valor de 1 para 2, uma vez que a rotina utilizada para  $N_c = 2$  é bastante diferente daquela utilizada para  $N_c = 1$ . Entretanto, para valores de horizonte de controle superiores a 2, em virtude da dificuldade de ajuste do controlador para estes casos, não foi possível concluir a simulação de 1000 minutos para nenhum valor de perturbação nos testes realizados.

### 4.2.1 Comportamento do modelo fenomenológico em malha aberta

As mesmas perturbações propostas para os testes do controlador foram impostas ao modelo em malha aberta, utilizando o programa do modelo fenomenológico. Com isto, espera-se conseguir realizar uma comparação entre os resultados com e sem a ação do controlador. Estes resultados obtidos em malha aberta foram inseridos juntos aos resultados obtidos com ação do controlador na forma gráfica utilizando uma linha tracejada (vide gráficos das Figuras 4.9 a 4.11, 4.14, 4.15, 4.18, 4.19, e 4.26 a 4.29).

### 4.2.2 Resposta utilizando DMC (Dynamic Matrix Control)

Os resultados obtidos do controle DMC utilizando modelo de convolução (MORO, 1992) foram inseridos ao lado dos resultados do controlador utilizando modelo interno em redes neurais, em um dos teste realizados. Tal procedimento teve como objetivo efetuar uma comparação entre estes controladores, avaliando principalmente o tempo de resposta e a amplitude das mesmas nas variáveis controladas. Este teste foi efetuado simulando as mesmas condições da literatura, sendo as figuras ali existentes transferidas por meio de uma fotocopiadora; portanto, sua resolução ficou ligeiramente prejudicada.

A estratégia de otimização proposta por MORO (1992) e reproduzida aqui, foi a de maximizar a severidade da reação. As condições da perturbação utilizando este modelo são mostradas na Tabela 4.6. Os gráficos das Figuras 4.26 a 4.29 representam as respostas obtidas por Moro no teste de maximização da severidade.

Tabela 4.6 Dados referentes às condições operacionais do controle preditivo DMC utilizando um modelo de convolução (MORO, 1992).

<b>Variáveis manipuladas</b>	vazão de ar < 240kNm <sup>3</sup> /h
	abertura da válvula de catalisador regenerado < 90%
	383,3m <sup>3</sup> /h < vazão de carga < 416,7m <sup>3</sup> /h
<b>Variáveis controladas</b>	temperatura da carga > 219°C
	650°C < temperatura das fases densas do regenerador, 1° e 2° estágios < 720°C
	70% < Severidade da reação catalítica < 85%
	535°C < temperatura da reação < 545°C
	variação na temperatura de reação < 1°C/min
<b>Parâmetros de controle</b>	período de execução do algoritmo = 1min.
	horizonte de controle = 1min.
	horizonte de predição = 12min.
	fatores de supressão nas variáveis manipuladas: $\lambda = 3,0$ para todas as variáveis
<b>Estratégia de otimização</b>	fatores de igual importância nas variáveis controladas: $\alpha_1=2; \alpha_2=2; \alpha_3=1; \alpha_4=1$
	perturbação na variável SETPDCV, alterando de 0,65kgf/cm <sup>2</sup> para 0,70kgf/cm <sup>2</sup>

### 4.2.3 Testes de desempenho do controlador proposto

É proposto realizar testes de desempenho no controlador utilizando as Redes Neurais como modelo interno efetuando degraus em algumas variáveis denominadas de variáveis perturbação de forma a obter as respostas a estas perturbações considerando o sistema aberto e o sistema com controle.

Para o teste de um problema regulador é proposto aplicar um degrau na variável Temperatura do Ar para o Regenerador, variável TAI (vide equação D.14, ANEXO D), alterando seu valor em +8%. Um segundo teste foi realizado considerando como perturbação o Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV; esta variável não pertencente diretamente ao controle proposto, mas apresenta uma malha de controle independente. O valor de referência foi alterado de  $0,65\text{kgf/cm}^2$  para  $0,70\text{kgf/cm}^2$ ; esta perturbação é considerada crítica para operação da unidade devido a elevada amplitude do degrau imposto. Um terceiro teste foi realizado, propondo avaliar o desempenho do controlador a partir de uma suposta alteração da qualidade da carga, representada neste caso por uma simulação de mudança na tendência da carga à formação de coque, alterando a Constante de Reação, variável KCC (vide Equação D.12, ANEXO D), em +10%. Um quarto teste foi efetuado propondo alteração da estratégia de operação que é feita simulando a produção de mais GLP ao invés de Nafta, alterando o valor de referência da variável SETSEV em +0,77% e SETTRX em +0,51%. Com objetivo de realizar uma comparação entre o DMC desenvolvido por MORO (1992) e o controlador proposto foi efetuado um teste simulando as mesmas variações propostas no estudo de Moro. Nas seções que se seguem estão apresentados os detalhes dos testes efetuados, e os gráficos obtidos como respostas.

#### 4.2.3.1 Problema regulador

Para o teste de controle regulador, foi considerado como variável de perturbação a Temperatura do Ar para o Regenerador, variável TAI. Esta variável apresenta um valor inicial de  $190^\circ\text{C}$  e o valor da perturbação foi de +8%, ou seja,  $+15,2^\circ\text{C}$ . Foi considerado amostragem de 4,0 em 4,0 minutos, com um horizonte de predição,  $N_p$ , igual a 10 instantes de amostragem e um horizonte de controle,  $N_c$ , igual a 1. Os fatores de ponderação nas ações de controle, representados por  $\lambda_i$ , que restringem as ações nas variáveis manipuladas

foram:  $1,0e-3$  para TFP,  $3,0e-4$  para RAI,  $6,0e-4$  para RTF, e  $5,0e-2$  para CTCV; e os fatores de igual importância, representados por  $\alpha_i$ , que controlam a relevância de cada variável controlada, foram:  $1,0e-3$  para TRG1,  $1,0e-5$  para TRG2,  $1,0e-4$  para SEV e  $5,0e-3$  para TRX. O filtro utilizado para o cálculo da trajetória de referência foi único, de  $9,0e-1$ , para todas as variáveis e a estratégia de otimização considerada para o teste foi a de manter fixa a Vazão de Carga da unidade, variável RTF. Com isto, o programa de controle procurou manter as variáveis controladas dentro de uma faixa estreita de variação alterando todas as demais variáveis manipuladas, RAI, CTCV e TFP.

Os gráficos das Figuras 4.9 a 4.11 mostram as respostas à perturbação degrau de  $+15,2^\circ\text{C}$  na variável TAI; estas respostas são apresentadas em forma comparativa entre sistema em malha aberta (linha tracejada) e com atuação do controlador (linha cheia). O início da ação de controle e o início da perturbação são destacados nesses gráficos.

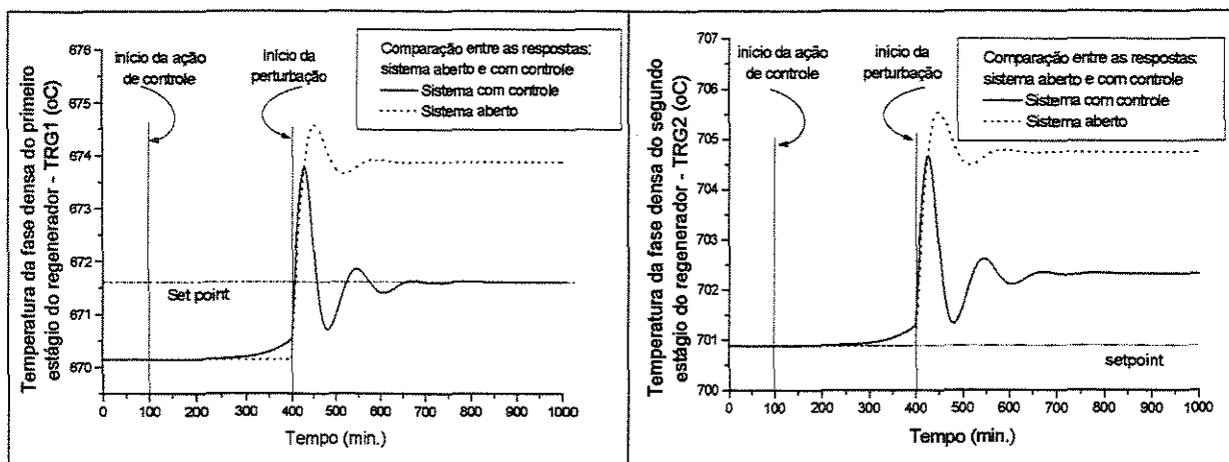


Figura 4.9 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis controladas: Temperaturas das Fases Densas do Regenerador, primeiro estágio, TRG1 (esquerda) e segundo estágio, TRG2 (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação  $+8\%$ .

Os gráficos da Figura 4.9 correspondem as respostas nas variáveis TRG1 e TRG2. Conforme era esperado, a elevação de TAI implicou em uma elevação imediata de ambas as temperaturas, resultando na elevação da temperatura do catalisador regenerado que por sua vez elevou também a temperatura do reator e a severidade da reação. Estes aumentos foram corrigidos simultaneamente por ação do controlador que reduziu gradualmente a vazão de ar, a abertura da válvula de catalisador regenerado e a temperatura da carga. A

vazão de carga foi mantida fixa na mesma faixa operacional que estava antes de ocorrer a perturbação, conforme foi definido pela ação do otimizador (vide Figura 4.13)

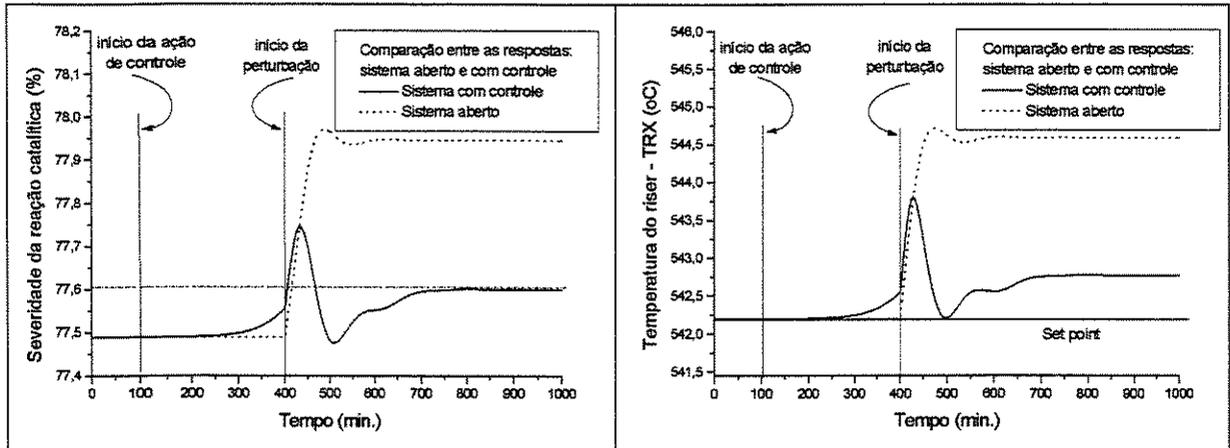


Figura 4.10 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis controladas: Severidade da Reação Catalítica, SEV (esquerda) e Temperatura de Saída do Riser, TRX (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8%.

As variáveis TRG2 e TRX, conforme se observa nos gráficos da direita nas Figuras 4.9 e 4.10, se apresentaram um pouco acima dos seus valores de referência. Na variável TRG2, isto é justificado devido à relação entre a vazão de ar entre os dois estágios do regenerador ser fixa, não sendo possível controlar uma variável independente da outra, conforme já dito; na variável TRX observa-se também uma dependência entre esta variável e a severidade da reação catalítica, claramente visto na expressão de cálculo da severidade que é função da variável TRX (vide equações D.6 e D.6a no ANEXO D). Apesar disto, como a amplitude dessas variações foi muito pequena, mantendo-se próximo do valor de referência, estes resultados foram considerados muito bons.

Na Figura 4.11 são mostrados os gráficos das variáveis associadas, Temperatura de Saída da Fase Diluída do segundo estágio do Regenerador, variável TD2 (esquerda), e Temperatura de Saída da Fase Diluída Geral, variável TDG (direita). Estas variáveis foram mantidas dentro da faixa de controle, conforme observado na Figura 4.11, em função da ação do controlador nas temperaturas dos leitos densos. Nestes gráficos é possível também observar como seria o comportamento destas variáveis sem ação de controle (linhas tracejadas, Figura 4.11).

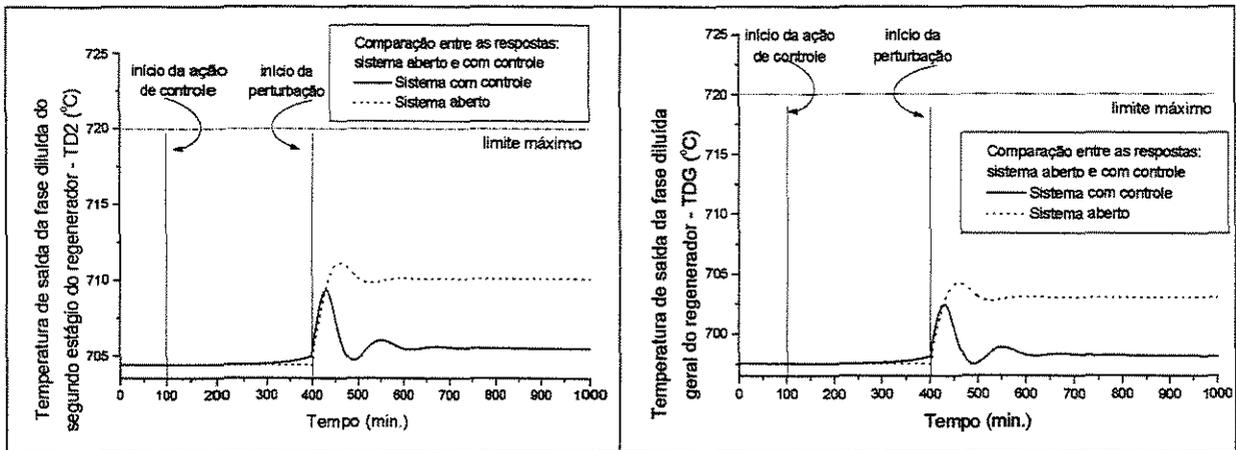


Figura 4.11 Problema Regulador. Resultados com ação do controlador (linha cheia), sistema aberto (linha tracejada). Variáveis associadas: Temperatura da Fase Diluída do segundo estágio do regenerador - TD2 (esquerda) e Temperatura de Saída Geral do Regenerador - TDG (direita). Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8%.

Nos gráficos seguintes, Figuras 4.12 e 4.13, são apresentadas as ações nas variáveis manipuladas obtidas pelo controlador. No gráfico correspondente à Vazão de Carga, variável RTF (Figura 4.13 esquerda), é perfeitamente visível a estratégia proposta pelo otimizador de manter fixa esta variável no seu valor inicial (representando uma reta horizontal no valor  $404,2\text{Nm}^3/\text{h}$ ).

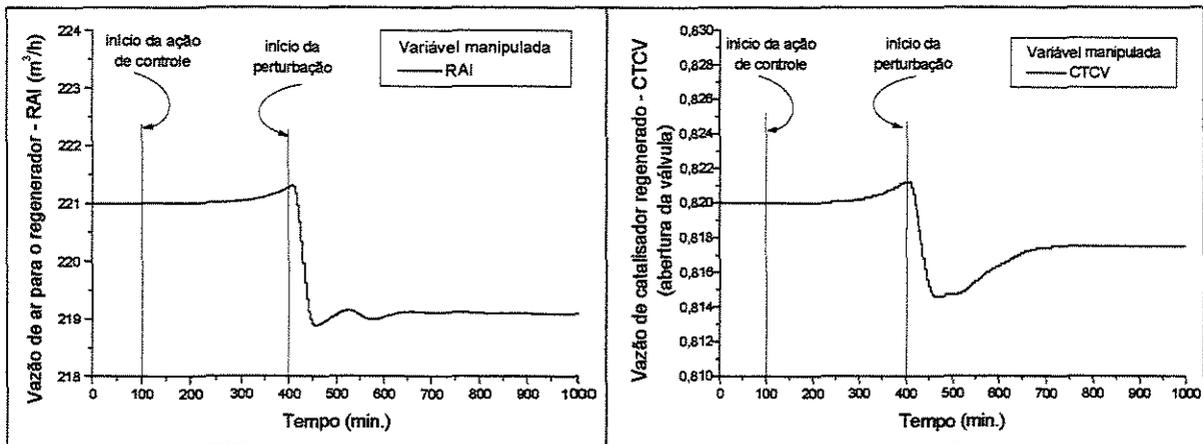


Figura 4.12 Problema Regulador. Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização manter a variável RTF fixa. Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8%.

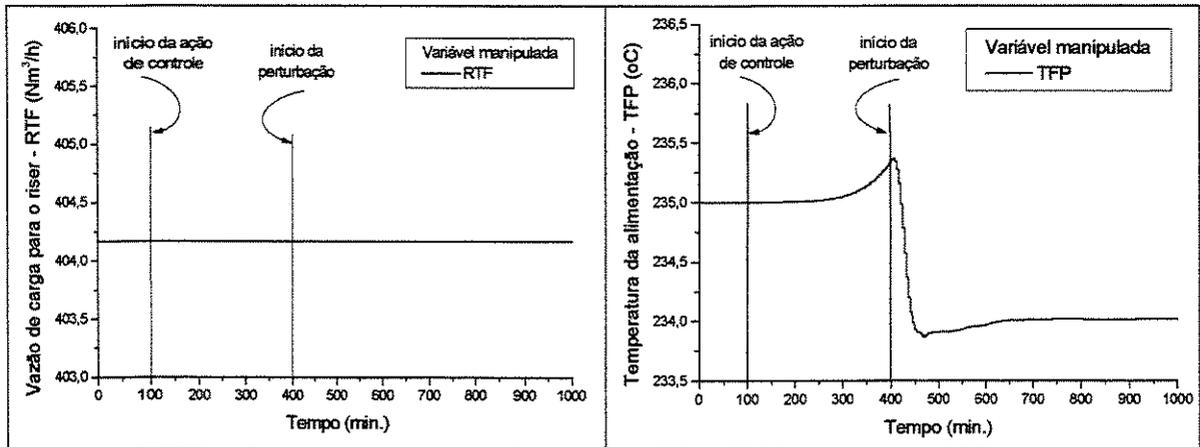


Figura 4.13 Problema Regulador. Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de controle manter a variável RTF fixa. Perturbação: Temperatura do Ar para o Regenerador, TAI variação +8%.

#### 4.2.3.2 Problema regulador para uma perturbação agressiva

Num segundo teste, na tentativa de verificar o desempenho do controlador em condições mais severas, foi dada uma perturbação no valor de referência do Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV. Uma alteração nesta variável afeta diretamente a vazão de catalisador para o *Riser*, numa intensidade difícil de ser quantificada. Uma perturbação degrau foi feita alterando de  $0,65 \text{ kgf/cm}^2$  para  $0,70 \text{ kgf/cm}^2$  nesta variável, correspondendo a 7,7% de variação. Também foi realizada neste teste a inserção de um ruído de intensidade 1,5% nos sinais fornecidos pelo programa fenomenológico, que aqui representa a unidade industrial, antes da chamada da rotina do programa de controle. Conforme foi dito na etapa de treinamento (CAPÍTULO III), o objetivo do ruído aqui foi também o de avaliar o desempenho do controlador em uma situação que representasse de forma mais real as condições da unidade industrial, para que pudesse ser testada a robustez do modelo.

Os fatores de ponderação para este teste nas variáveis manipuladas,  $\lambda_i$ , foram:  $1,0\text{e-}3$  para TFP,  $3,0\text{e-}4$  para RAI,  $6,0\text{e-}4$  para RTF, e  $5,0\text{e-}2$  para CTCV; e os fatores de igual importância,  $\alpha_i$ , para as variáveis controladas, foram:  $1,0\text{e-}3$  para TRG1,  $1,0\text{e-}5$  para TRG2,  $1,0\text{e-}4$  para SEV e  $5,0\text{e-}3$  para TRX. O filtro utilizado para o cálculo da trajetória de referência foi único, de  $9,0\text{e-}1$  para todas as variáveis e a estratégia de otimização considerada para o teste foi novamente a de manter fixa a vazão de carga da unidade. O intervalo de amostragem foi de 4,0 em 4,0 minutos e os horizontes considerados foram

$N_p = 10$  e  $N_c = 1$ . Procurou-se manter os mesmos ajustes do controlador obtidos no teste anterior, conforme se pode observar, mesmo sabendo *a priori* que isto poderia ser prejudicial ao seu desempenho.

Os gráficos das Figuras 4.14 e 4.15 a seguir apresentam as respostas à perturbação na variável SETPDCV com a inserção de ruído nos sinais das variáveis controladas, e nos gráficos das Figuras 4.16 e 4.17 são mostrados os degraus fornecidos pelo controlador.

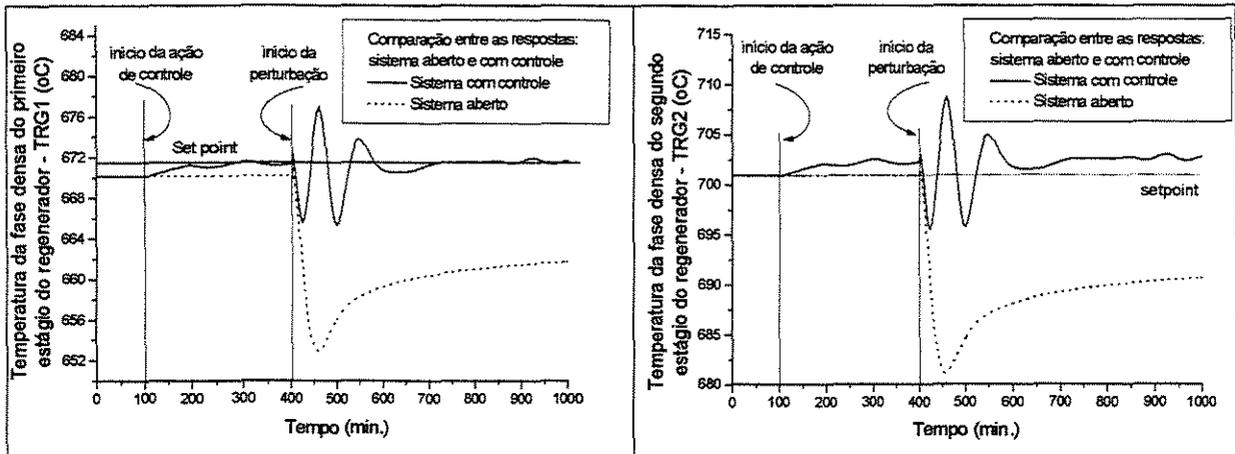


Figura 4.14 Resultados obtidos da ação do controlador (linha cheia) e os resultados do sistema aberto (linha tracejada). Variáveis controladas: Temperatura da Fase Densa do primeiro estágio do Regenerador, TRG1 (esquerda) e Temperatura da Fase Densa do segundo estágio do Regenerador, TRG2 (direita). Perturbação: variável SETPDCV intensidade de +7,7%.

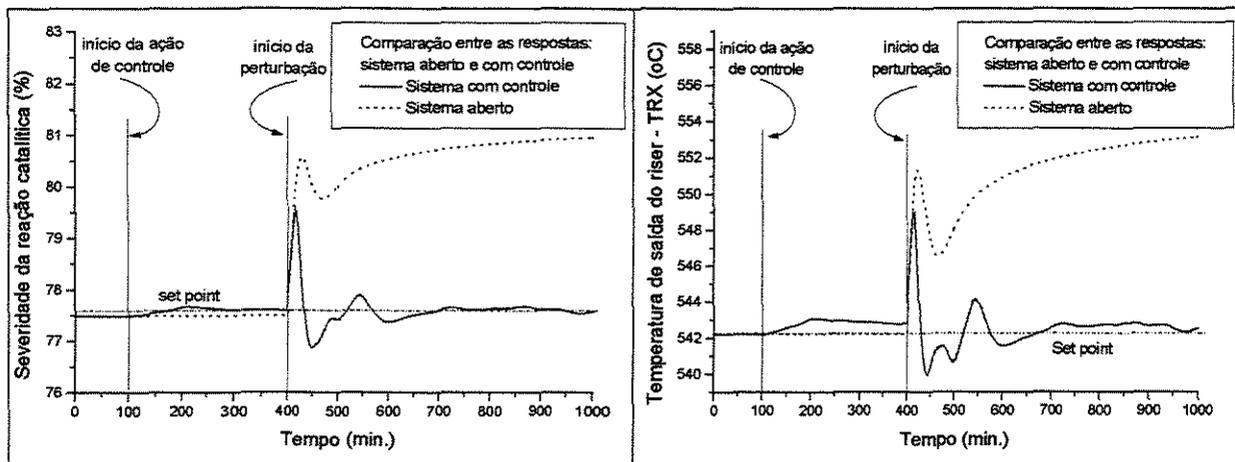


Figura 4.15 Resultados obtidos da ação do controlador (linha cheia) e os resultados do sistema aberto (linha tracejada). Variáveis controladas: Severidade da Reação Catalítica (esquerda) e Temperatura de Saída do Riser, TRX (direita). Perturbação: variável SETPDCV intensidade de +7,7%.

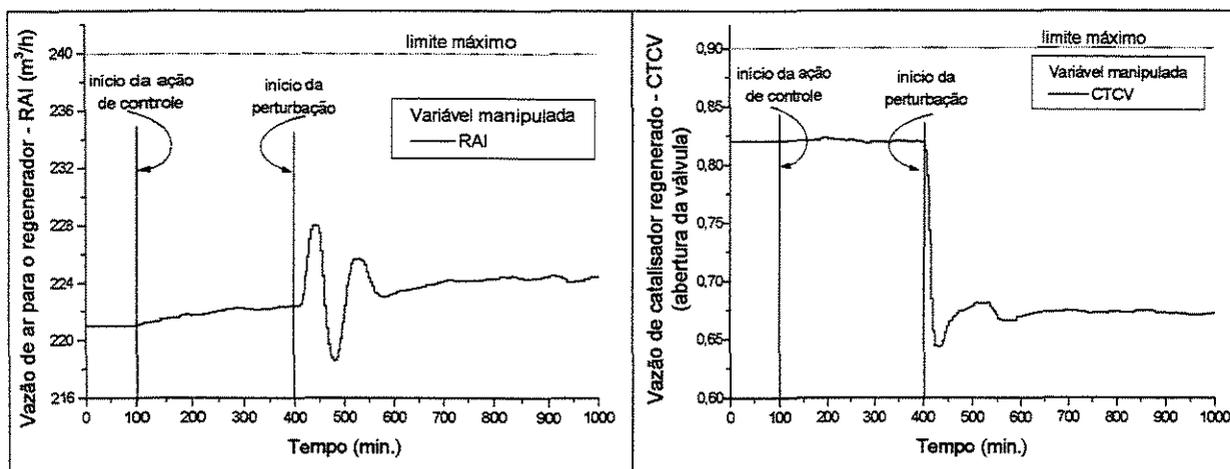


Figura 4.16 Ações do controlador nas variáveis manipuladas, RAI e CTCV, assumindo como otimização manter a variável RTF fixa. Resposta à perturbação degrau de +7,7% no Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV.

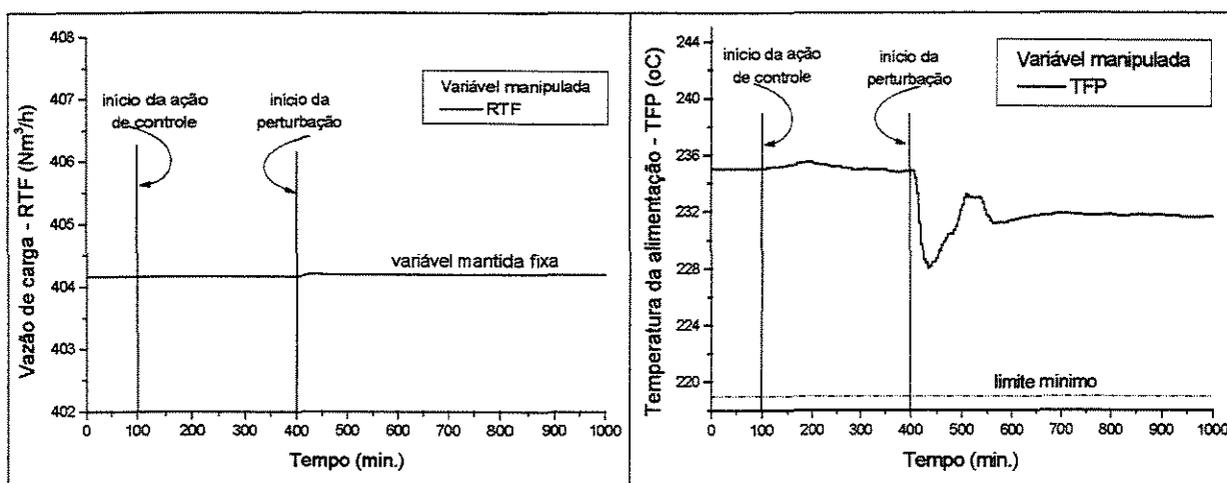


Figura 4.17 Ações do controlador nas variáveis manipuladas, RTF e TFP, assumindo como otimização manter a variável RTF fixa. Resposta à perturbação degrau de +7,7% no Diferencial de Pressão entre o Regenerador e o Reator, variável SETPDCV.

Conforme se pode observar a inserção de ruído com intensidade de 1,5% nas variáveis do processo não exerceu nenhuma influência visível no comportamento das variáveis manipuladas ou controladas, o que confirma a robustez do controlador preditivo utilizando modelo em RNA. O comportamento oscilatório observado pode ter sido causado pela elevada agressividade da perturbação ou por questões relacionadas a dificuldade de ajuste do controlador.

#### 4.2.3.3 Mudança de qualidade da carga

Uma situação considerada usual da unidade de FCC corresponde ao aumento da formação de coque devido a algum distúrbio nas condições de operação do reator ou

mesmo por alteração da qualidade da carga. Isto reflete diretamente na necessidade de se aumentar a temperatura do Regenerador. Este aumento resulta numa alteração da quantidade de catalisador em circulação, o que por sua vez altera também a temperatura do reator e a conversão. Desta forma, visando verificar a ação do controlador frente uma situação real dessa natureza, foi dado uma perturbação degrau na Constante de Reação de formação de coque usada pelo programa do modelo fenomenológico para determinar a taxa de formação de coque, variável KCC (ANEXO D). Como estratégia de controle, foi proposta a minimização de carga. Os fatores de ponderação para este teste nas variáveis manipuladas,  $\lambda_i$ , foram:  $1,0e-3$  para TFP,  $3,0e-2$  para RAI,  $6,0e-4$  para RTF, e  $5,0e-2$  para CTCV; e os fatores de igual importância,  $\alpha_i$ , para as variáveis controladas, foram:  $1,0e-3$  para TRG1,  $1,0e-5$  para TRG2,  $1,0e-4$  para SEV e  $5,0e-3$  para TRX. O filtro utilizado para o cálculo da trajetória de referência foi único, de  $9,7e-1$  para todas as variáveis e a estratégia de otimização considerada para o teste foi a de minimizar a produção alterando a Vazão de Carga da unidade, variável RTF. O intervalo de amostragem foi de 4,0 em 4,0 minutos e os horizontes considerados foram os mesmos do teste anterior  $N_p = 10$  e  $N_c = 1$ .

Os gráficos das Figuras 4.18 e 4.19 apresentam os resultados da ação do controlador frente à esta perturbação juntamente com a estratégia de redução de carga da unidade. Nesta simulação também foi inserido um ruído de 1,5% nos sinais das variáveis controladas.

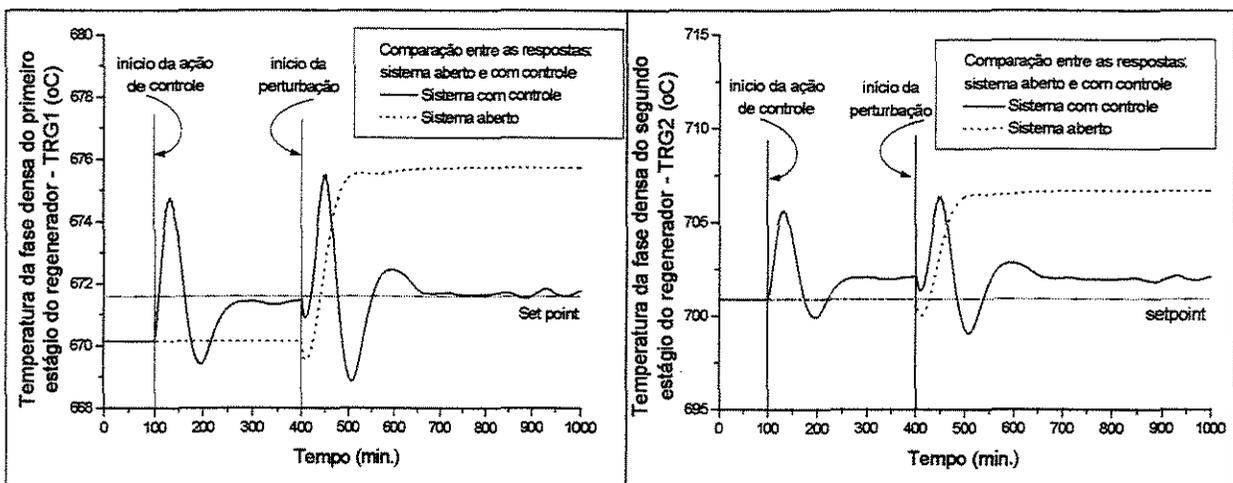


Figura 4.18 Resultados obtidos do teste de simulação de mudança de qualidade de carga, comparando sistema aberto (linha tracejada) e controlador (linha cheia). Variáveis controladas: TRG1 (esquerda) e TRG2 (direita). Perturbação: variável KCC, intensidade +10%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: minimizar a produção.

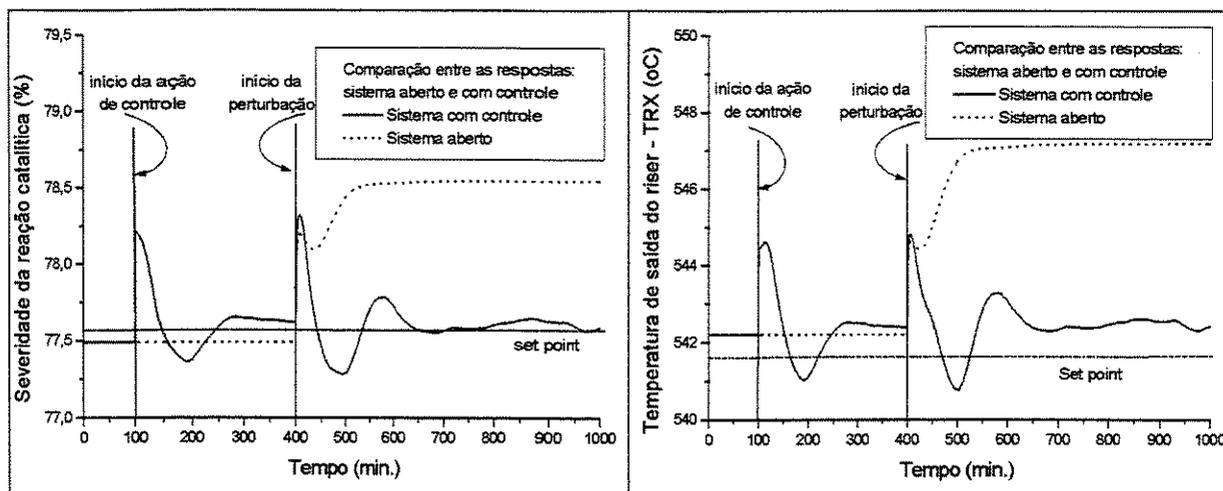


Figura 4.19 Resultados obtidos do teste de simulação de mudança de qualidade de carga, comparando sistema aberto (linha tracejada) e controlador (linha cheia). Variáveis controladas: Severidade da Reação Catalítica, SEV (esquerda) e Temperatura de Saída do *Riser*, TRX (direita). Perturbação: variável KCC, intensidade +10%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: minimizar a produção.

Conforme pode ser observado nas Figuras 4.18 e 4.19, com a redução da carga, houve imediato aumento da temperatura do reator e aumento da conversão, e como consequência, posterior aumento das temperaturas do Regenerador. O controlador reagiu reduzindo a circulação de catalisador, a Temperatura da Carga e a Vazão de Ar para o Regenerador (vide Figuras 4.20 e 4.21), trazendo as variáveis controladas para os seus valores de referência. Com a perturbação, no instante 400 minutos, houve imediato aumento da temperatura do reator e da severidade da reação catalítica e posterior aumento das temperaturas do regenerador. O controlador reagiu novamente reduzindo ainda mais a vazão de catalisador circulante e a temperatura da carga. Posteriormente reduziu a vazão de ar para o regenerador para reduzir as temperaturas do primeiro e segundo estágios. Esta ação conjunta causou reduções excessivas na conversão e temperatura do reator o que novamente acionou o controlador no sentido de ajustar a conversão elevando ligeiramente a circulação de catalisador regenerado e a temperatura da carga, o que corrigiu também as temperaturas do regenerador. A resposta do sistema aberto, sem ação do controlador, é mostrada na forma de uma linha tracejada. Os gráficos das Figuras 4.20 e 4.21 apresentam as ações do controlador para este teste.

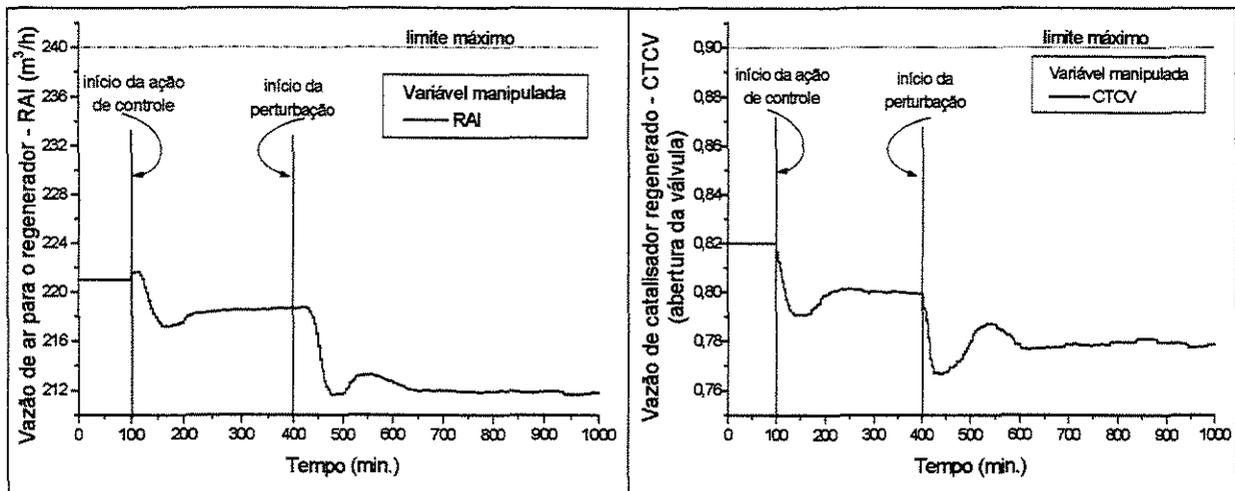


Figura 4.20 Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização minimizar a produção, como resposta à uma perturbação na variável KCC de intensidade +10%, com inserção de ruído de 1,5% nas variáveis controladas.

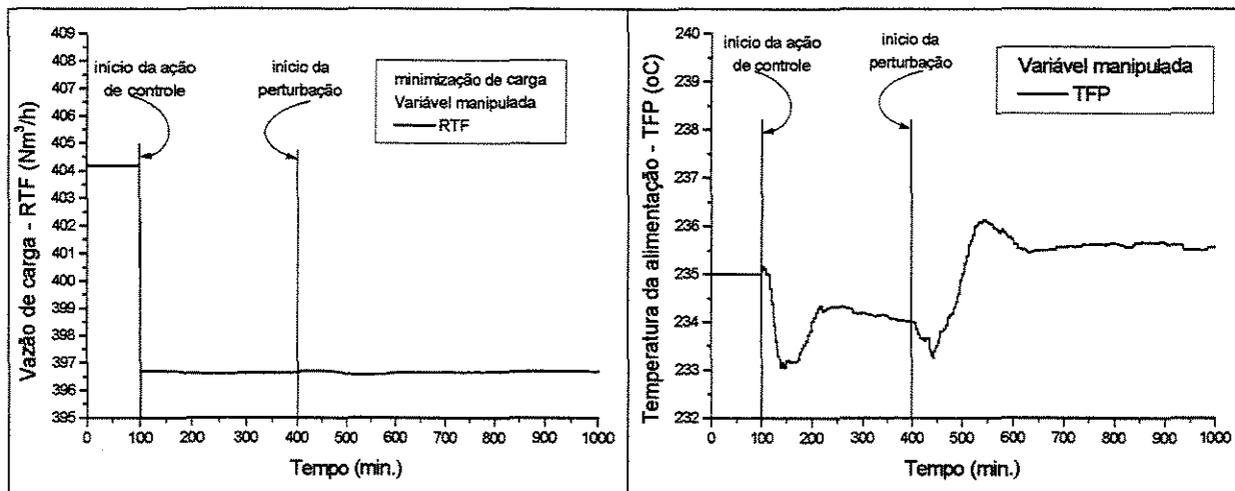


Figura 4.21 Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de otimização minimizar a produção, como resposta à uma perturbação na variável KCC de intensidade +10%, com inserção de ruído de 1,5% nas variáveis controladas.

Conforme se observa neste teste as ações de controle não foram afetadas com a presença de ruídos nos sinais das variáveis controladas, confirmando novamente a robustez das Redes Neurais Artificiais como modelo interno de um controlador preditivo.

#### 4.2.3.4 Problema servo-regulador

Conforme informações obtidas, (ODLOAK<sup>3</sup>, 2001), a unidade de FCC frequentemente precisa alterar a estratégia de produção para atender solicitações de

<sup>3</sup> Consulta pessoal ao Dr. Darci Odloak por ocasião da apresentação dos seminários do projeto RECOPE em Canela, RS, em nov. 2001.

mercado. Desta forma, foi proposto avaliar o desempenho do controlador frente a esta situação, considerando ainda uma perturbação degrau na variável Temperatura do Ar para o Regenerador, variável TAI, com intensidade de +8%. A inserção de um ruído de intensidade 1,5% nos sinais das variáveis controladas também foi efetuada. Os gráficos das Figuras 4.22 e 4.23 apresentam os resultados obtidos desta simulação nas variáveis controladas. Como estratégia do otimizador foi maximizado o valor de referência da Temperatura de Saída do *Riser*, para atender à solicitação de produção de GLP. Foram simulados 800 minutos neste teste, sendo mantidos os mesmos valores de início de atuação do controlador e de perturbação dos testes anteriores.

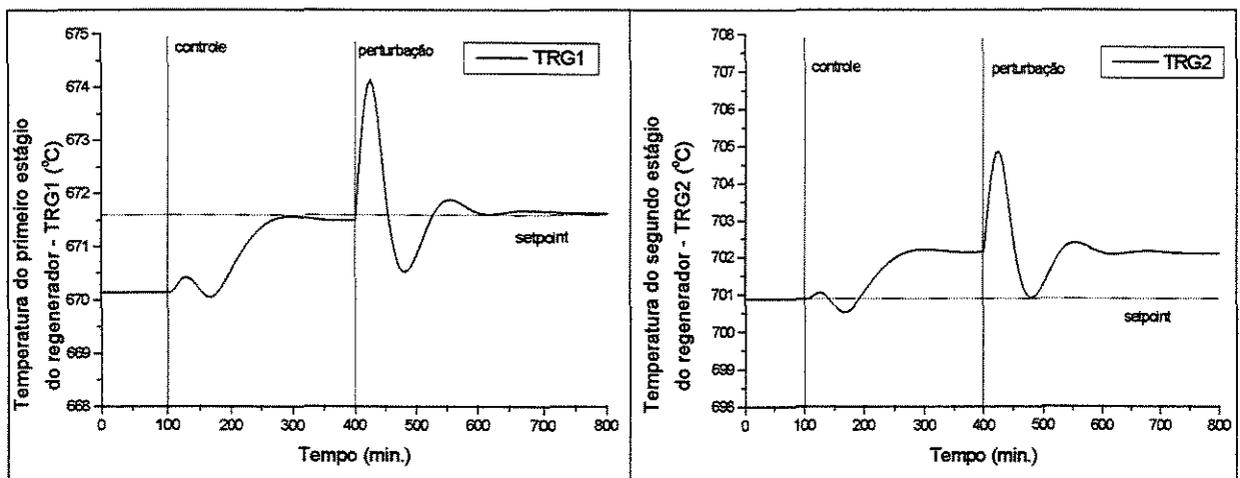


Figura 4.22 Resultados obtidos do teste de mudança de estratégia de produção. Variáveis controladas: TRG1 (esquerda) e TRG2 (direita). Perturbação: variável TAI com intensidade de +8%, com inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: maximizar a produção de GLP.

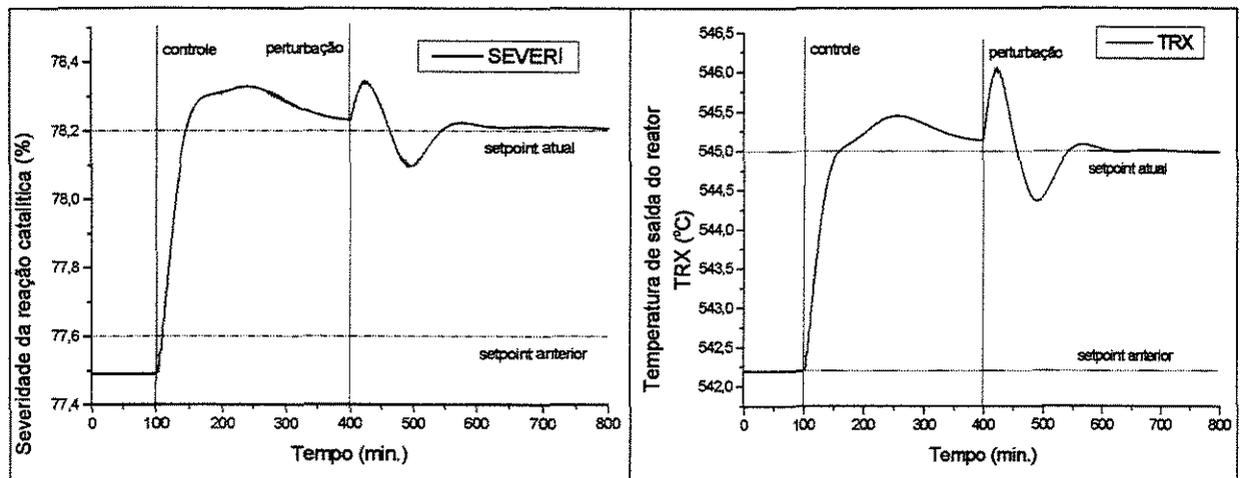


Figura 4.23 Resultados obtidos do teste de mudança de estratégia de produção. Variáveis controladas: Severidade da Reação Catalítica (esquerda) e TRX (direita). Perturbação: degrau na variável TAI com intensidade de +8%, e inserção de ruído de 1,5% nas variáveis controladas. Estratégia de otimização: maximizar a produção de GLP.

Os gráficos das Figuras 4.24 e 4.25 apresentam as respostas nas variáveis manipuladas para esta situação. Como as variáveis controladas TRX e Severidade da Reação Catalítica estão interrelacionadas, uma mudança no valor de referência de uma delas necessariamente irá afetar o valor de referência da outra, para atender à condição de estado estacionário.

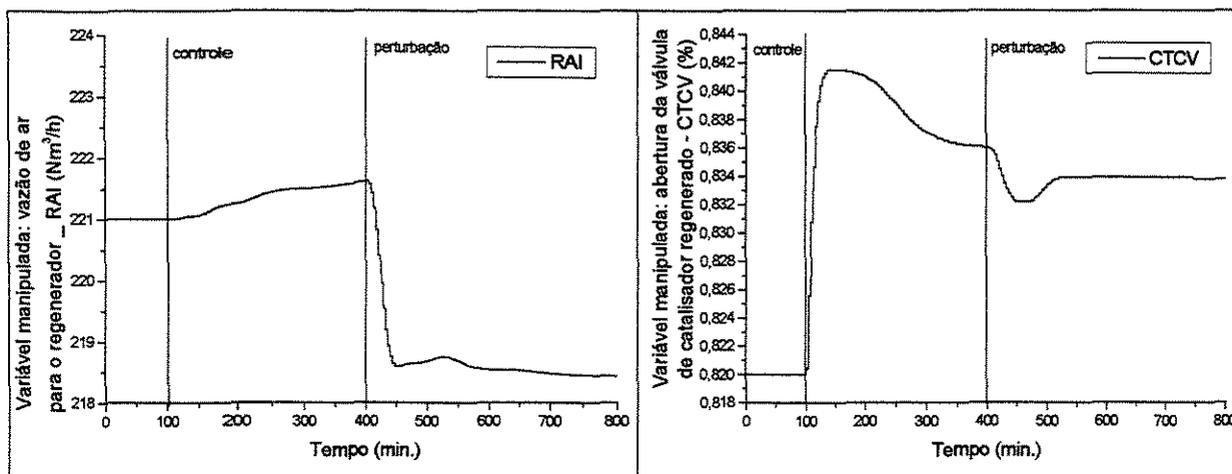


Figura 4.24 Resultados das ações do controlador nas variáveis manipuladas RAI e CTCV, assumindo como estratégia de otimização maximizar a produção de GLP ao invés de Nafta. Resposta à uma perturbação na variável TAI com intensidade de +8%, com inserção de ruído de 1,5% nas variáveis controladas.

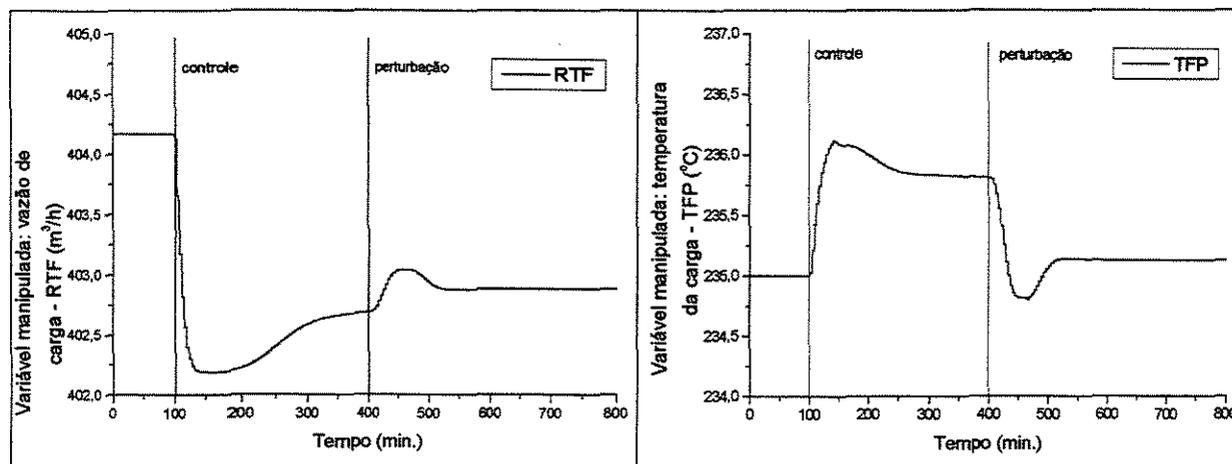


Figura 4.25 Resultados das ações do controlador nas variáveis manipuladas RTF e TFP, assumindo como estratégia de otimização maximizar a produção de GLP. Resposta à uma perturbação na variável TAI de intensidade +8%, com inserção de ruído de 1,5% nas variáveis controladas.

Novamente, a presença de ruído não afetou o desempenho das ações do controlador para esta situação.

#### 4.2.3.5 Comparação com o controle DMC

Na tentativa de efetuar uma comparação entre o controlador preditivo proposto e o controlador preditivo DMC existente, foi proposto efetuar uma simulação das condições encontradas no controlador DMC desenvolvido por Moro em sua dissertação de mestrado (MORO, 1992). Desta forma, um teste foi efetuado aplicando uma variação de 0,65 para  $0,70\text{kgf/cm}^2$  na variável perturbação *setpoint* do controlador de Pressão Diferencial entre Regenerador e Reator, variável SETPDCV. Como estratégia de controle, foi proposta a maximização de severidade, igual ao proposto no controle DMC. Os fatores de ponderação para este teste nas variáveis manipuladas,  $\lambda_i$ , foram:  $5,0\text{e-}2$  para TFP,  $5,0\text{e-}2$  para RAI,  $8,0\text{e-}2$  para RTF, e  $4,0\text{e-}2$  para CTCV; e os fatores de igual importância,  $\alpha_i$ , para as variáveis controladas, foram:  $1,0\text{e-}3$  para TRG1,  $1,0\text{e-}6$  para TRG2,  $1,0\text{e-}3$  para SEV e  $1,0\text{e-}3$  para TRX. O filtro utilizado para o cálculo da trajetória de referência foi único, de  $9,0\text{e-}1$  para todas as variáveis. O intervalo de amostragem foi de 5,0 em 5,0 minutos e o horizonte  $N_p = 10$ . O horizonte de controle foi alterado para 2, utilizando outra rotina em linguagem FORTRAN. Os gráficos das Figuras 4.26 a 4.29 apresentam os resultados comparativos de ambos os controladores, juntamente com os resultados sem ação de controle (linha tracejada).

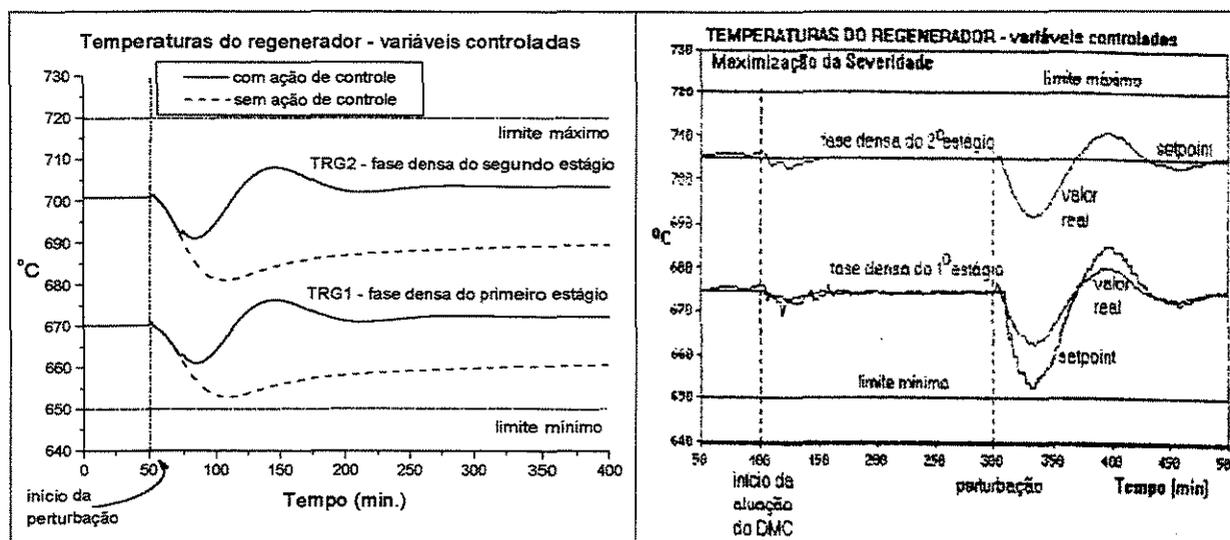


Figura 4.26 Resposta comparativa entre os resultados das Temperaturas de Saída das Fases Densas do Regenerador, primeiro e segundo estágios – TRG1 e TRG2. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992).

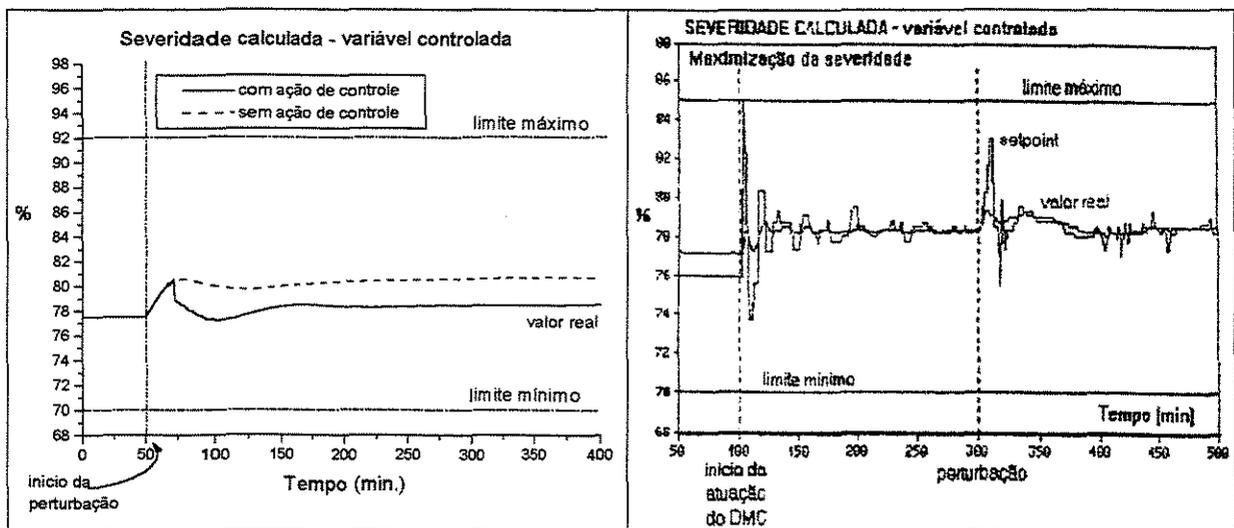


Figura 4.27 Resposta comparativa entre os resultados da Severidade da Reação Catalítica. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992).

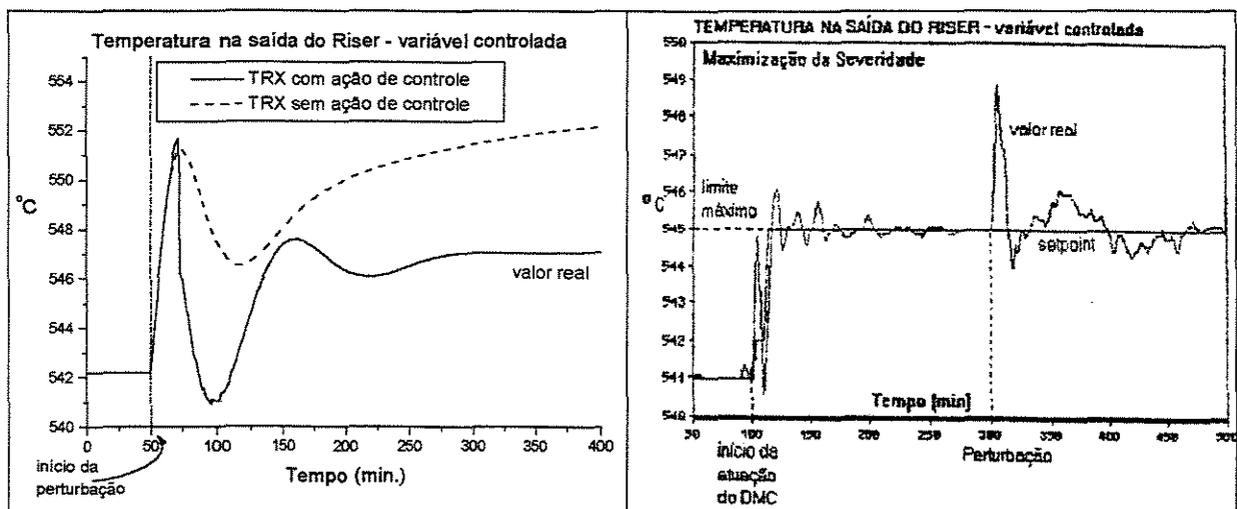


Figura 4.28 Resposta comparativa entre os resultados da Temperatura de Saída do Riser – TRX. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992).

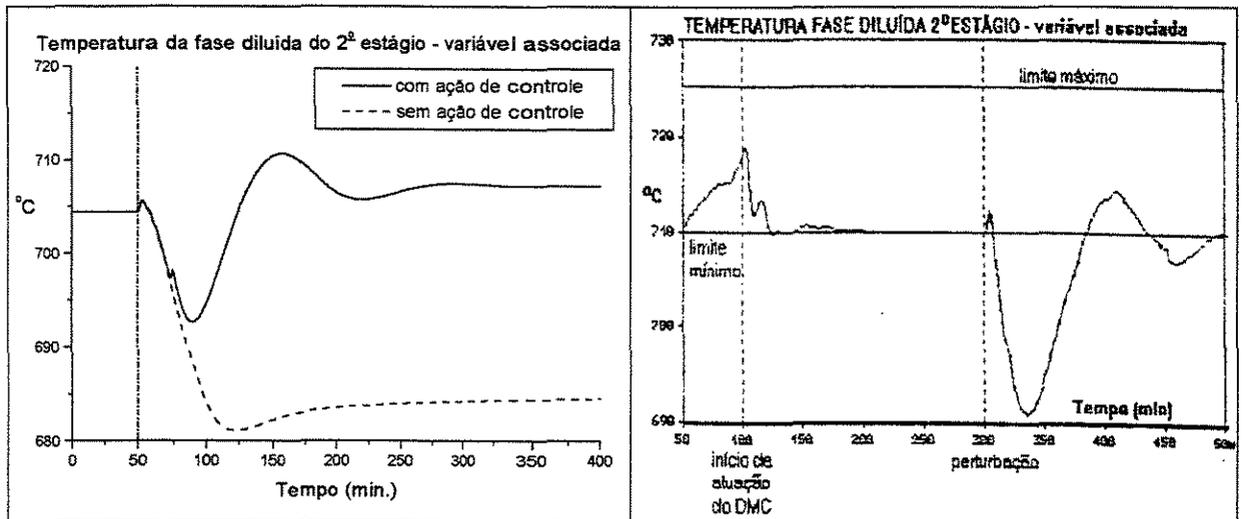


Figura 4.29 Resposta comparativa entre os resultados da Temperatura da Fase Diluída do Segundo Estágio do Regenerador – TD2. No gráfico da esquerda estão representados o resultado do controlador proposto (linha cheia) e o resultado sem ação do controlador (linha tracejada); e no gráfico da direita estão representados os resultados do DMC (MORO, 1992).

Analisando os gráficos das Figuras 4.26 a 4.29 acima, o primeiro fato que se observa é que após início da perturbação, o tempo necessário para se atingir o estado estacionário com ação de controle foi praticamente o mesmo, próximo a 200 minutos, para ambos os controladores. Outro fato que se observa é que as amplitudes das respostas também foram praticamente iguais para ambos. Isto comprova, pelo menos, igual desempenho para o controle proposto comparando com o DMC existente. Levando em consideração o tempo de processamento, o controlador baseado em Redes Neurais Artificiais se mostra superior, uma vez que sua resposta é extremamente mais rápida, mesmo se considerarmos a possibilidade de elevar o horizonte de controle para valores superiores a 1. É necessário que se esclareça que o tempo de processamento do controle via RNA, uma vez efetuado o treinamento *off-line*, é da ordem de frações do minuto, inferior portanto ao tempo de simulação e ao tempo de amostragem considerados; e, o ganho no esforço computacional do controle DMC só foi possível de ser obtido com o “desmembramento do problema de programação linear em dois níveis: o nível estático onde são tratadas as restrições e o nível dinâmico onde o controle multivariável é feito usando os *setpoints* obtidos no nível estático” (MORO, 1992).

Comparando os resultados obtidos do controlador, considerando  $N_c = 2$  (Figuras 4.26 a 4.29), com os resultados obtidos considerando  $N_c = 1$  (Figuras 4.14 e 4.15), observa-se uma melhora razoável nas ações de controle, com redução das oscilações. Entretanto, os

ajustes do controlador foram extremamente difíceis de serem realizados para este horizonte ( $N_c = 2$ ), e não se obteve êxito na tentativa de se elevar  $N_c$  para valores superiores a 2. Convém observar que a rotina de minimização escrita em linguagem Fortran para  $N_c = 1$  é diferente da rotina para  $N_c = 2$ , o que por sua vez difere também para  $N_c > 2$ , apesar de utilizarem o mesma subrotina NCONF para minimização da função objetivo, (vide Capítulo III). O aumento deste horizonte resulta no aumento do número de variáveis a otimizar, aumentando a dificuldade de ajuste do controlador.

## CAPÍTULO V

### CONCLUSÕES E SUGESTÕES

Um modelo interno do controlador preditivo para unidade FCC, representando a dinâmica das principais variáveis de controle foi desenvolvido e testado, utilizando a técnica de Inteligência Artificial - as Redes Neurais Artificiais. O modelo fenomenológico existente na literatura que representa esta dinâmica, já devidamente validado com a unidade industrial, foi usado para obtenção dos conjuntos de dados para treinamento da rede. Este modelo também foi usado para representar a unidade industrial no teste de desempenho do controlador desenvolvido. Como treinamento da referida rede, foi utilizada a modalidade supervisionada, denominada *Backpropagation*.

Não foi tecido neste estudo nenhum comentário a respeito da obtenção de mínimos locais por esse método de treinamento, pois a preocupação maior foi obter uma configuração que atendesse aos requisitos preestabelecidos de erro entre rede e modelo rigoroso, não importando se este resultado fosse obtido de um mínimo local ou não. Diversas arquiteturas de redes, utilizando diferentes números de nós na camada intermediária foram testadas, utilizando como critério para seleção da rede ótima o erro relativo, limitado em no máximo 1,0% entre os resultados obtidos da rede neural e os resultados obtidos do modelo.

A configuração escolhida baseada nesse critério de erro para representar a unidade de FCC foi de uma rede totalmente conectada com alimentação positiva com 3 camadas contendo: 8 nós na primeira camada, 15 nós na camada intermediária, e 4 nós na camada de saída. Na etapa de identificação do modelo foi inserido um ruído aleatório nos sinais das variáveis controladas do modelo fenomenológico visando testar a robustez do modelo em RNA. A rede escolhida apresentou bons resultados apresentando robustez mesmo utilizando uma precisão de apenas  $5,23E-4$  no gradiente da função objetivo, gerando uma função objetivo, que representa o somatório dos erros quadráticos dos resultados da rede de  $1,09E-1$ . Estes resultados permitem concluir que o modelo escolhido é capaz de representar fielmente o modelo fenomenológico, mesmo considerando a não linearidade do processo e elevada interação entre suas variáveis de operação, sendo também considerado adequado para ser usado como modelo interno de um controlador preditivo.

Um controlador preditivo utilizando as RNA como modelo interno foi desenvolvido e inserido na rotina do modelo fenomenológico, propondo controle e otimização. Visando testar a robustez do controlador proposto e simular as condições de sinais ruidosos normalmente encontradas numa unidade industrial foi inserido um ruído aleatório nos sinais das variáveis controladas provenientes da simulação nos testes do controlador. Diversas situações foram testadas: problema de controle regulador, problema de controle servo-regulador, simulação de mudança de produção de Nafta para GLP, entre outros, para diferentes horizontes de predição e controle, sendo efetuado comparações com sistema aberto e com o controle DMC.

O controle multivariável utilizando redes neurais como modelo interno aplicado ao simulador do processo FCC demonstrou um desempenho muito bom em todas as simulações efetuadas, principalmente se considerarmos que as perturbações impostas foram bem mais agressivas do que normalmente são permitidas nessas unidades. Em todos os testes efetuados o controlador manteve a estabilidade do processo levando as variáveis controladas para os seus valores de referência mesmo na presença de ruídos, permitindo também obter uma estratégia de otimização do controle. A utilização de  $N_c = 2$  melhorou consideravelmente a ação do controlador quando comparado com horizonte de controle  $N_c = 1$ , reduzindo as oscilações observadas com este controle no teste efetuado.

Isto demonstra que um controlador preditivo multivariável baseado em RNA é perfeitamente capaz de controlar um sistema não linear do porte da unidade do FCC, no qual elevada interação entre suas variáveis operacionais e fortes restrições estão presentes, apresentando robustez, uma característica das redes neurais artificiais. Isto nos permite extrapolar que são boas as expectativas para uma futura utilização na unidade industrial, principalmente devido à sua simplicidade, robustez e facilidade de implementação, a despeito da dificuldade de sintonia do controlador. Como sugestões para trabalhos futuros, podem ser citados:

- O modelo fenomenológico representativo do FCC, Modelo Kellogg Orthoflow F., está sendo revisado atualmente (conforme ZANIN, 2001<sup>4</sup>). Neste estudo é proposto uma atualização e melhoria do modelo. Proponho que seja feito o mesmo estudo de

---

<sup>4</sup> ZANIN, A. C. Integrating Real-time optimization into the Model Predictive Controller of the FCC system. *V Simpósio Brasileiro de Automação Inteligente – SBAI. Canela, RS. 2001*. Disponível em: <<http://www.delet.ufrgs.br/vsbai>> e informação verbal. 2001.

identificação e controle utilizando as Redes Neurais Artificiais para este modelo revisado;

- A ação de controle do Regenerador (nas temperaturas dos leitos densos, primeiro e segundo estágios) apresentou desempenho um pouco prejudicado devido a razão de ar para os estágios ser considerada fixa no próprio modelo fenomenológico. É proposto realizar um estudo de identificação e controle incluindo a razão de ar para os dois estágios do Regenerador como nova variável manipulada, de forma a aumentar a eficiência do controle de suas temperaturas de saída;
- Como o desempenho do Regenerador é baseado no teor de  $O_2$  livre nos gases de combustão, é proposto realizar um estudo de inferenciação do teor de  $O_2$  nos gases de combustão, visando inseri-lo no modelo fenomenológico e dessa forma avaliar diretamente o desempenho do Regenerador como função desse teor, ao invés de utilizar as temperaturas dos leitos, utilizando um modelo Híbrido de Redes Neurais;
- Como foi observado que o desempenho do controlador pode ser melhorado ainda mais considerando o horizonte de controle maior que 1, é proposto realizar novos testes utilizando o mesmo modelo de identificação, fazendo  $N_c = 2$  e valores superiores para este horizonte;
- Durante o processo de identificação, foi observado que uma vez obtidos os pesos e *bias* para determinada arquitetura de rede neural, estes poderiam ser utilizados como *inputs* para novo treinamento com mesma arquitetura ao invés de se utilizar valores *randômicos*, com a vantagem de reduzir muito o tempo de CPU neste treinamento. Isto poderia ser útil tornando viável o treinamento em linha (*on-line*) na unidade industrial. É proposto testar a possibilidade de treinamento com o modelo fenomenológico, simulando um treinamento em linha, utilizando como entrada para treinamento os valores de pesos e *bias* obtidos do treinamento *off-line*. Este procedimento seria de extrema importância numa eventual mudança de procedência do petróleo utilizado com conseqüente mudança da qualidade da matéria prima da FCC.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGUILARA, R., GONZÁLEZ, J, RAMÍREZ, J. A., BARRÓN, M. Control of a fluid catalytic cracking unit based on proportional-integral reduced order observers. *Journal of Chemical Engineering* v. 75, p. 77-85, 1999.
- ALI, E. E. AND ELNASHAIE, S., Non-linear model predictive control of industrial type IV fluid catalytic cracking (FCC) units for maximum gasoline yield, *Ind. and Engng. Chem. Res.*, v. 36, p. 389-398, 1997.
- ALI, E. and ZAFIRIOU, E. On the Tuning of Nonlinear Model Predictive Control Algorithms. 1993. *Technical Research Report, Institute for Systems Research. National Science Foundation Engineering Research Center – Program (NSFD CD 8803012)*, TR 93-26. In: E-Mail: zafiriou@src.umd.edu . Acessado em: 20 jan. 2000.
- ALVES, R. M. B. and NASCIMENTO, C. A. O. Neural Network Based Approach for an Industrial Isoprene Process Optimization. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 967., 2001, Melbourne, Australia*. Proceedings...Melbourne, Australia, 2001.
- ANSARI, R. M. and TADÉ, M. O. Constrained nonlinear multivariable control of a fluid catalytic cracking process. *Journal of Process Control* v. 10, p. 539-555, 2000. Disponível em: <<http://www.elsevier.com/locate/jprocont>>. Acessado em: 03 dez. 2000.
- ANTONIADES, C., CHRISTOFIDES, P. D. Feedback control of nonlinear differential difference equation systems. *Chemical Engineering Science* v. 54 p. 5677-5709, 1999.
- ARANDES J. M. and LASA H. I. – Simulation and Multiplicity of Steady States in Fluidized FCCUs. *Chemical Engineering Science*, v. 47, n. 9-11, 2535-2540, 1992.

BALCHEN, J.G., LUNGQUIST D. AND STRAND S., State-space predictive control, *Chemical Engineering Sci.* v. 47 p. 787-798, 1992.

BAUGHMAN, D. R. and LIU, Y. A. *Neural Networks in Bioprocessing and Chemical Engineering*. London: Academic Press, Inc., 1995, 489 p..

BHAT, N. and McAVOY, T. J. Use of Neural Nets for Dynamic Modeling and Control of Chemical Process Systems. *Computers chem. Engng.*, v. 14, n. 4/5, p. 573-583, 1990.

BHAT, N. and McAVOY, T. J. Determining Model Structure for Neural Models by Network Stripping. *Computers chem. Engng.*, v. 16, n. 4, p. 271-281, 1992.

CASTIER, M. *Subroutine for the Minimization of a Multivariable Function using the Conjugate Gradient Method of FLETCHER AND REEVES (1964)*. Based on a skeleton of the routine TMSSJ of M. L. MICHELSEN. (Instituttet for Kemiteknik - DTH - Denmark). Programa de Engenharia Química – COPPE. Universidade Federal do Rio de Janeiro, 1990.

DE SOUZA JR, M. B. *Redes Neurais Multicamadas aplicadas a modelagem e controle de processos químicos*. Rio de Janeiro: COPPE/UFRJ,. 1993. 124 p. Tese (doutorado).

DI MASSIMO, C., MONTAGUE, G. A., WILLIS, M. J., THAM, M. T. and MORRIS, A. J. Towards Improved Penicillin Fermentation via Artificial Neural Networks. *Computers chem. Engng.*, v. 16, n. 4, p. 283-291, 1992.

DONG, D., McAVOY, T. J. and ZAFIRIOU, E. Batch-to-Batch Optimization Using Neural Network Models. *Ind. Eng. Chem. Research*. v. 35, p. 2269-2276, 1996.

EDGAR, T. F. and HIMMELBLAU, D. M. Optimization of Chemical Processes, p. 206-208, *McGraw-Hill Intl. Ed.*, New York, 1988.

ENDER, L. and MACIEL FILHO, R. Utilização de modelo dinâmico neural em estratégia de controle preditivo multivariável. *XIII Congresso Brasileiro de Engenharia Química – COBEQ. XIX Interamerican Congress of Chemical Engineering*. Anais do congresso, 2000.

FALTSI-SARAVÉLOU, O. VASALOS, I. A. and DIMOGIORGAS, G. FBSim: A model for Fluidized Bed Simulation – II. Simulation of an industrial Fluidized Catalytic Cracking Regenerator. *Computers Chem. Engng.* v. 15, n. 9, p. 647-656, 1991.

FENG, E. and JIN, Y. A Neural Methodology for Batch Process Optimizing Control. *Second IEEE Conference on Control Applications*, p. 13-16, September 1993.

FILETI, A. M. F. *Controle avançado de Processos: Adaptativo, Preditivo e Fuzzy. Modelagem Matemática via Redes Neurais. Aplicações em Processos Químicos.* (material especialmente elaborado para o curso ministrado na Escola Politécnica da Universidade Federal da Bahia). UNICAMP – Faculdade de Engenharia Química. Campinas, Brasil. Jul. 1998.

FILETI, A. M. F. and PEREIRA, J. A. F. R. Adaptive and predictive control strategies for batch distillation: Development and experimental testing. *Computers chem. Engng.* v. 21, Suppl., p. S1227-S12231, 1997.

FILETI, A. M. F., PEREIRA FILHO, R. D., PEDROSA, L. S. and PEREIRA, J. A. F. R. A comparison of control strategies for bath distillation. *International Symposium on Advanced Control of Chemical Process – ADCHEM 2000*. p. 635-640. Pisa, Italy – June 2000.

FONSECA E. F. *Controle Preditivo Baseado em Redes Neurais de Fermentação Alcoólica Contínua*. Recife: DEQ/UFPE, 1998, Dissertação (Mestrado).

GÁLVEZ, J. M. and SOUZA, S. R. Multivariable modeling and control of a Fluid Catalytic Cracking Converter unit. *XIII Congresso Brasileiro de Engenharia Química – COBEQ. XIX Interamerican Congress of Chemical Engineering*. Anais do congresso, 2000.

GOH, K. C., WU, F. and WALSH, S. Control Design for Nonlinear Process Models using Linear Robust Control Methods: An FCCU Example. *Computers Chem. Engng.*, v. 21, Suppl., p. S595-S600, 1997.

GREAVES, M. A., MUJTABA, I. M. and HUSSAIN, M. A. Model Development Through Pilot Plant Experiments and Neural Networks for Optimal Control of Batch Distillation. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 591., 2001, Melbourne, Australia*. Proceedings...Melbourne, Australia, 2001.

GROSDIDIER, P., MASON, A., AIATOLAHTI, A., HEINONEN, P. and VANHAMÄKI, V. FCC Unit Reactor-Regenerator Control. *Computers chem. Engng.*, v. 17, n. 2, p. 165-179, 1993.

HAN, I. S. & CHUNG, C. B. Dynamic modeling and simulation of a fluidized catalytic cracking process. Part II: Property estimation and simulation Published by Elsevier Science Ltd. *Chemical Engineering Science* 56 (2001) p. 1973-1990, 2001b.

HAN, I. S. & CHUNG, C. B. Dynamic modeling and simulation of a fluidized catalytic cracking process. Part I: Process modeling Published by Elsevier Science Ltd. *Chemical Engineering Science* 56 p.1951-1971, 2001a.

HAYKIN, S. *Neural Networks – A Comprehensive Foundation*. NJ: Macmillan Publishing Co., 1994, 696 p.

HECHT-NIELSEN, R. Theory of the backpropagation network. *Proceedings, Int. Joint. Conf. on Neural Networks, Washington, DC*, v. 1, p. 593-605, 1989.

HERNÁNDEZ, E. and ARKUN, Y. Study of the Control-Relevant Proprieties of Backpropagation Neural Network Models of Nonlinear Dynamical Systems. *Computers chem. Engng.*, v. 16, n. 4, p. 227-240, 1992.

HODGSON, M. C. J., FOSKETT, S. J. and YANIK, S. J. Catalyst Management Concepts to Cope with Mass-Transfer Limitations in the Fluid Catalytic Cracking Unit. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 1749., 2001, Melbourne, Australia*. Proceedings. Melbourne, Australia, 2001.

HOLCOMB & MORARI. PLS/Neural Networks. *Computers Chem. Engng.*, Pergamon Press Ltd, v.16 (4), p. 393-411, 1992.

HOSKINS, J. C. and HIMMELBLAU, D. M. Process Control via Artificial Neural Networks and Reinforcement Learning. *Computers chem. Engng.*, v. 16, n. 4, p. 241-251, 1992.

ISCOL L. The dynamics stability of a fluid catalytic cracker. *Joint Automatic Control Conference*, Atlanta, Georgia, 602-607, 1970.

ISHIKAWA, T., NATORI, Y., LIBERIS, L. and PANTELIDES, C. C. Modeling and Optimization of an Industrial Batch Process for the Production of Dioctyl Phthalate. *Compters Chem. Engng.*, v. 21, Suppl., p. S1239-S1244, 1997.

JACOB S. M., GROSS, B., VOLTZ, S. E. and WEEKMAN, V. W., A lumping and reaction scheme for catalytic cracking. *AIChE. Journal* , v. 22, n. 4, p. 701-713, 1976.

JAGANNATHAN, S. and LEWIS, F. L. Identification of Nonlinear Dynamical Systems Using Multilayered Neural Networks. *Automatica*, v. 32, n. 12, p. 1707-1712, 1996.

JAMIESON, A. E. Dynamic Simulation in Process Control Design. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 1670., 2001, Melbourne, Australia*. Proceedings. Melbourne, Australia, 2001.

JOSEPH, B., WANG, F. H. and SHIEH, D. S. –S. Exploratory Data Analysis: A Comparison of Statistical Methods with Artificial Neural Networks. *Computers Chem. Engng.*, v. 16, n. 4, p. 413-423, 1992.

KALRA, L. and GEORGAKIS, C. The effects of Operational Characteristics of Catalytic Cracking Reactors on the Closed-loop Performance of Linear Model Predictive Controllers. *Computers chem. Engng.*, v. 4, p. 401-415, 1996.

KAMARTHI, S. V. and PITTNER, S. Accelerating neural network training using weight extrapolations. *Neural Networks. Pergamon, Elsevier Science Ltd.*, v. 12, p. 1285-1299, 1999. Disponível em: <<http://www.eselvier.com/locate/neunet>>. Acessado em: 14 set. 2000.

KAVURI, S. N. and VENKATASUBRAMANIAN, V. Combining Pattern Classification and Assumption-based Techniques for Process Fault Diagnosis. *Computers Chem. Engng.*, v. 16, n. 4, p. 299-312, 1992.

KHANDALEKAR, P. D. and RIGGS, J. B. Nonlinear Process Model Based Control and Optimization of a Model IV FCC Unit. *Computers Chem. Engng.*, v. 19, n. 11, p. 1153-1168, 1995.

KIM, S. -J., LEE, M., PARK, S., LEE, S. -Y. and PARK, H. A Neural Linearizing Control Scheme for Nonlinear Chemical Processes. *Computers Chem. Engng.*, v. 21, n. 2, p. 187-200, 1997.

KRISHNA, A. S. and PARKIN, E. S. Modeling the Regenerator in Commercial Fluid Catalytic Cracking Units. *Chemical Engng. Prog.* April (57) 1985.

KROTHAPALLY, M. and PALANKI, S. A Neural Network Strategy for Batch Process Optimization. *Computers chem. Engng.*, v. 21, Suppl., p. S463-S468, 1997.

KURIHARA, H. *Optimal Control of Fluid Catalytic Cracking Processes*. MIT, Cambridge, MA: Ph.D. Thesis, 1967.

LEE, E. and GROVES, F. R. Mathematical model of the fluidized bed catalytic cracking plant. *Trans. Soc. Compt. Sim.*, v. 2, p. 219-236, 1985.

LEE, W. and KUGELMAN, A. M. – Number of steady-state operating points and local stability of open-loop fluid catalytic cracker. *Ind. Eng. Chem. Pocess Des. Dev.*, v. 12, p. 197-204, 1973.

LEVIN, A. U. and NARENDRA, K. S. Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization. *IEEE Transactions on Neural Networks*, v. 4, n. 2, March 1993.

LEVIN, A. U. and NARENDRA, K. S. Control of Nonlinear Dynamical Systems Using Neural Networks – Part II: Observability, Identification, and Control. *IEEE Transactions on Neural Networks*, v. 7, n. 1, January 1996.

LIMA, E. L. e OLIVEIRA, S. L. *Tendências em Controle de Processos*. Apostila do curso. Escola Piloto de Engenharia Química. Programa de Engenharia Química, COPPE/UFRJ. 1997.

MACFARLANE R. C. & REINEMAN R. C., Multivariable Optimizing Control of a Model IV Fluid Catalytic Cracking Unit, *AIChE Spring National Meeting*, March 18-22, Orlando, Florida, 1990.

MORO, L. F. L. and ODLOAK, D. Constrained Multivariable Control of Fluid Catalytic Cracking Converters. *J. Proc. Cont.*, v. 5, n. 1, p. 29-39, 1995.

MORO, L. F. L. *Desenvolvimento de um Controlador Preditivo Multivariável para um Conversor Industrial de Craqueamento Catalítico*. São Paulo: USP, 1992, 77 p. Dissertação (Mestrado)

NARENDRA, K. S. and MUKHOPADHYAY, S. Adaptive Control Using Neural Networks and Approximate Models. *IEEE Transactions on Neural Networks*, v. 8, n. 3, May 1997.

NARENDRA, K. S. Neural Networks for Control: Theory and Practice. *Proceedings of the IEEE*, Oct 1996. v. 84, n. 10.

NASCIMENTO JR., C. L. *Artificial Neural Networks in Control and Optimization*. 1994. 209 p. Thesis (Doctor of Philosophy) – Faculty of Technology, University of Manchester, Control Systems Center – UMIST, Manchester, UK.

NELSON, M. M. and ILLINGWOTH, W. T. *A Practical Guide to Neural Nets*. Addison-Wesley Publishing Company, Inc., 1991, 344 p.

NIEDERBERGER, J., FUSCO, J. M., CID, E. A. e SANDES, E. F. SIMCRAQ<sup>OT</sup> – Um sistema avançado para a simulação e otimização do processo de FCC. *XIII Congresso Brasileiro de Engenharia Química – COBEQ. XIX Interamerican Congress of Chemical Engineering*. Anais do congresso, 2000.

NIKRAVESH, M. FARELI, A. E. and STANFORD, T. G. Model Identification of Nonlinear Time Variant Process via Artificial Neural Network. *Computers chem. Engng.*, v. 20, n. 11, p. 1277-1290, 1996.

PACHOVSKY, R. A. and WOJCIECHOWSKI, B. W. Effects of charge stock composition on selectivity in the cracking of neutral distillates. *Can. Journal of Chem. Engng.*, v. 53, p. 659-665, dec. 1975.

PEDROSA, L. S., NUNES, R. L., PEREIRA, J. A. F. R. and FILETI, A. M. F. A Neural Network Based Inference System to the on-line estimation of Polymer Quality. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 424., 2001, Melbourne, Australia*. Proceedings. Melbourne, Australia, 2001.

PEREIRA FILHO, R. D. Desenvolvimento e implementação de controladores *Fuzzy* para uma coluna de destilação em batelada. *Universidade Estadual de Campinas – UNICAMP, SP, 1999*.

POLLARD, J. F., BROUSSARD, M. R., GARRISON, D. B. and SAN, K. Y. Process Identification Using Neural Networks. *Computers chem. Engng.*, v. 16, n. 4, p. 253-270, 1992.

PRANATYASTO, T. N., and QIN, S. J. Model Predictive Control of FCC units with Integrated Sensor Validation and Process Fault Diagnosis. *International Symposium on Advanced Control of Chemical Processes*. p. 569-574, Italy - June, 2000.

PRETT, M. P. and GARCIA, C. E. *Fundamental Process Control*. USA MA: Butterworth Publishers, Stoneham, 1988.

ROBITAILLE, B., MARCOS, B., VEILLETTE, M. and PAYRE, G. Modified Quasi-Newton Methods for Training Neural Networks. *Computers Chem. Engng.*, v. 20, n. 9, p. 1133-1140, 1996.

RUIZ C. A. and SONNET, A. Neural Networks Applications in the process Industry. *XIII Congresso Brasileiro de Engenharia Química – COBEQ. XIX Interamerican Congress of Chemical Engineering*. Anais do congresso, 2000.

RUMELHART, D. E., HINTON, G. E. and WILLIAMS, R. J. Learning internal representations by error propagation. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. v. 1, (Rumelhart, D. E. and McClelland, J. L., eds). Foundations the MIT Press. Cambridge. 1986.

SALOMON, R. and VAN HEMMEN, J. L. Accelerating Backpropagation through Dynamic Self-Adaptation. *Neural Networks*, Pergamom press, Elsevier Science Ltd., v. 9., n. 4, p. 589-601, 1996.

SANTOS, V. M. L. *Identificação e Controle Preditivo Baseado em Redes Neurais de Processos de Craqueamento Catalítico em Leito Fluidizado*. Recife, PE: DEQ/UFPE, 101p. 2000b. dissertação (mestrado)

SANTOS, V. M. L., CARVALHO, F. R. and De SOUZA Jr., M. B. Predictive Control Based on Neural Networks: An Application to a Fluid Catalytic Cracking Industrial Unit. *Brazilian Journal of Chemical Engineering*. v.17 n. 04-07, p. 897-902. 2000a.

SARMA, P. AND RENGASWAMY, R. Multivariable gain-scheduled fuzzy logic control of a fluidized catalytic cracker unit. *Computers and Chemical Engineering* v. 24 p. 1083-1089, 2000.

SAVKOVIC', -STEVANOVIC', J. Neural Networks for Process Analysis and Optimization: Modeling and Applications. *Computers chem. Engng.* v. 18. n. 11/12. p. 1149-1155, 1994.

SIMPSON, P. K. *Artificial Neural Systems: Foundations, Paradigms, Applications and Implementations*. New York: Pergamon Press, Inc. 1990, 203 p.

STEPHANOPOULOS, G. and HAN, C. Intelligent Systems in Process Engineering: A Review. *Computers Chem. Engng.*, v. 20, n. 6/7, p. 743-791, 1996.

TVRZSKÁ DE GOUVÊA, M. and ODLOAK, D. One-layer real-time optimization of LPG production in the FCC unit: procedure, advantages and disadvantages. *Computers Chem. Engng.*, v. 22, Suppl., S191-198, 1998.

VENUTO, P. B. and HABIB, E. T. Catalyst feedstock – Engineering interactions in fluid catalytic cracking. *Cat. Rev. sci. Eng.*, v. 18, n. 1, 1978.

WANG, H., OH, Y. and YOON, E. S. Strategies for Modeling and Control of Nonlinear Chemical Processes using Neural Networks. *Computers Chem. Engng.* v. 22, Suppl., p. S832-S862, 1998.

WANG, X. Z., CHEN, B. H., YANG, S. H., C. MCGREAVY. Application of wavelets and neural networks to diagnostic system development, 1, feature extraction. *Computers and Chemical Engineering*, v. 23, p. 899-906, 1999a.

WANG, X. Z., CHEN, B. H., YANG, S. H., C. MCGREAVY. Application of wavelets and neural networks to diagnostic system development, 2, an integrated framework and its application. *Computers and Chemical Engineering*, v. 23 p. 945-954, 1999b.

WANG, Z. and ZHU, T. An efficient learning algorithm for improving generalization performance of radial basis function neural networks. *Neural Networks. Pergamon, Elsevier Science Ltd.*, v. 13, p. 545-553, 2000. Disponível em:  
<<http://www.elsevier.com/locate/neunet>>. Acessado em: 14 set. 2000.

WEEKMAN, V. W., Lumps, models and kinetics in practice. *AIChE. Monograph Series*, v. 75, n. 11, 1979.

WHITELEY, J. R. and DAVIS, J. F. Knowledge-based Interpretation of Sensor Patterns. *Computers Chem. Engng.*, v. 16, n. 4, p. 329-346, 1992.

XU, C., GAO, J. and LIN, S. Simulation of the flow and Reaction and Application of the Reaction-Terminating Technique in FCC Riser Reactor. In: *6<sup>th</sup> WORLD CONGRESS OF CHEMICAL ENGINEERING, 1214., 2001, Melbourne, Australia*. Proceedings. Melbourne, Australia, 2001.

YAMADA, T. and YABUTA, T. Neural Network Controller Using Autotuning Method for Nonlinear Functions. *IEEE Transactions on Neural Networks*, v. 3, n. 4, July 1992.

YANG, S. H., CHUNG, P. W. H., WANG, X. Z. and MCGREAVY, C. Multi-objective Constraint Control for FCC Reactor-Regenerator System. *Computers Chem. Engng.*, v. 22, Suppl. p. S831-S834, 1998.

YANG, Y., YIZONG, C., ZHAO, R. and GOVIND, R. Process Optimization Using Neural Networks. *IEEE Inter. Conf. On Neural Networks*, Orlando, FL. Proceedings Piscataway., v. 7, p. 4635-4639, 1994.

ZAINUDDIN, Z. and EVANS, D. J. Acceleration of the Back Propagation through Dynamic Adaptation of the Learning Rate. *Intern. J. Computer Math.*, v. 65, p. 1-17, 1997.

ZANIN, A. C. Integrating Real-time optimization into the Model Predictive Controller of the FCC system. *V Simpósio Brasileiro de Automação Inteligente – SBAI. Canela, RS. 2001*. Disponível em: <<http://www.delet.ufrgs.br/vsbai>> Comunicação pessoal. 2001.

ZANIN, A. C., M. TVRZSKÁ DE GOUVÊA, M. AND ODLOAK, D. Industrial implementation of a real-time optimization strategy for maximizing production of LPG in a FCC unit. *Computers and Chemical Engineering*, v. 24 p. 525–531. 2000a.

ZANIN, A. C., M. TVRZSKÁ DE GOUVÊA, M. AND ODLOAK, D. Comparing different real-time optimization strategies for the FCC Catalytic Converter. *International Symposium on Advanced Control of Chemical Process – ADCHEM 2000*. p. 803-808. Pisa, Italy – June 2000b.

ZHAN, J. and ISHIDA, M. The Multi-step Predictive Control of Nonlinear SISO Processes with a Neural Model Predictive Control (NMPC) Method. *Computers chem. Engng.*, v. 21, n. 2, p. 201-210, 1997.

ZHAO, F., OU, J. and DU, W. Pattern-based fuzzy predictive control for a chemical process with dead time. *Engineering Applications of Artificial Intelligence. Pergamon, Elsevier Science Ltd.*, v. 13, p. 37-45, 2000. Disponível em:  
<<http://www.elsevier.com/locate/engappai.html>>. Acessado em: 14 set. 2000.

ZHENG, Y. -Y., Dynamic modeling and simulation of a catalytic cracking unit. *Computers Chem. Engng.*, v.18 (1), p. 39-44, Pergamon Press Ltd 1994.

**ANEXOS**

## ANEXO A

ALGORITMO DE TREINAMENTO VIA RETROPOGAGAÇÃO (*BACKPROPAGATION*)

A seguir é apresentado um algoritmo para atualização dos pesos e *bias* durante o treinamento da rede:

- *Passo 0*: Inicialmente é atribuído valores aleatórios pequenos aos pesos e *bias*, evitando assim problemas como simetria (caso fossem gerados números iguais) e saturação (caso fossem gerados números muito grandes para os pesos). Uma boa opção é gerar números entre -1 e +1 (RUMELHART & MCCLELLAND, 1986 apud DE SOUZA JR., 1993);

- *Passo 1*: Para cada padrão  $p$  ( $p = 1, 2, \dots, N_p$ ), existe um conjunto de entradas  $S_{pj,0}$  ( $j = 1, 2, \dots, n_i$ ) – onde  $n_i$  corresponde ao número de neurônios na camada de entrada; e um conjunto de saídas desejadas  $t_{pl}$  ( $l = 1, 2, \dots, n_L$ ) – onde  $n_L$  corresponde ao número de neurônios na camada de saída L. Apresenta-se um padrão  $p$  por vez à rede;

1. A passagem pela primeira camada de neurônios não lineares produz as seguintes ativações:

$$S_{pj,1} = f(S_{pj,0}) \quad (j = 1, 2, \dots, n_i) \quad (\text{A.1})$$

onde  $f(\ )$  é dada pela função *sigmoidal*, (Equação 3.4);

2. À saída da camada escondida tem-se as ativações,

$$S_{pj,2} = f(\lambda_{pj,2}) \quad (\text{A.2})$$

$$\lambda_{pj,2} = \left[ \sum_{i=1}^{n_h} w_{ji1} \cdot S_{pi,1} \right] + \theta_{j,2} \quad j = 1, 2, \dots, n_h \quad (\text{A.3})$$

tal que  $f(\ )$  é dada pela função *sigmoidal* (Equação 3.4), e  $n_h$  representa o número de neurônios na camada escondida;

3. À saída da rede tem-se,

$$S_{pj,L} = f(\lambda_{pj,L}) \quad (\text{A.4})$$

$$\lambda_{pj,L} = \left[ \sum_{i=1}^{n_h} w_{ji,2} \cdot S_{pi,2} \right] + \theta_{j,L} \quad j = 1, 2, \dots, n_L \quad (\text{A.5})$$

tal que  $f(\ )$  é dada por função *sigmoidal* (Equação 3.4);

- *Passo 2*: Os pesos são atualizados usando o método *steepest descent*, (Equação 3.10), sendo que as equações que fornecem os gradientes, são apresentadas no ANEXO B.

*Obs.1*: na implementação do método pode-se atualizar os pesos após apresentação de cada padrão ou após apresentação de todos os padrões. No presente estudo, foi escolhido atualizar os pesos após apresentação de todos os padrões;

*Obs.2*: os padrões deverão ser normalizados antes de serem apresentados à rede.

Repetem-se os passos 1 e 2 até que o erro fornecido por  $E$  (Equação 3.7) seja minimizado, ou seja, até que o erro seja menor que um valor delta muito pequeno. Aqui, foi adotado como critério de convergência a comparação do gradiente do erro  $E$  da função objetivo com um valor delta, e não a comparação do erro  $E$  da própria função objetivo com este valor, o que na verdade, apresentam mesmos resultados.

## ANEXO B

CÁLCULO DOS ELEMENTOS DE  $\underline{VE}(W)$  DO MÉTODO *STEEPEST DESCENT*

São apresentadas aqui as equações que fornecem o gradiente do erro em função das variáveis independentes (pesos e *bias*) para o método do passo decrescente – *steepest descent*, exemplificando para três camadas. (DE SOUZA JR., 1993; HAYKIN, 1994).

Dado a função representada pela expressão B.1,

$$E = \sum_{p=1}^P E_p \quad (\text{B.1})$$

onde  $E$  representa o erro e,

$$E_p = \frac{1}{2} \sum_{i=1}^{n_i} (S_{pi,L} - t_{pi})^2 \quad (\text{B.2})$$

Para os pesos  $w_{j2}$  entre a camada escondida e a camada de saída, calcula-se a derivada pela regra da cadeia, ou seja,

$$\frac{\partial E}{\partial w_{j2}} = \sum_{p=1}^P \frac{\partial E_p}{\partial S_{pj,L}} \frac{\partial S_{pj,L}}{\partial \lambda_{pj,L}} \frac{\partial \lambda_{pj,L}}{\partial w_{j2}} = \sum_{p=1}^P (S_{pj,L} - t_{pj}) f'(\lambda_{pj,L}) S_{pi,2} \quad (\text{B.3})$$

Para os *bias*,  $\theta_{j,L}$ , da última camada, calcula-se também pela regra da cadeia,

$$\frac{\partial E}{\partial \theta_{j,L}} = \sum_{p=1}^P \frac{\partial E_p}{\partial S_{pj,L}} \frac{\partial S_{pj,L}}{\partial \lambda_{pj,L}} \frac{\partial \lambda_{pj,L}}{\partial \theta_{j,L}} = \sum_{p=1}^P (S_{pj,L} - t_{pj}) f'(\lambda_{pj,L}) \quad (\text{B.4})$$

Para os pesos  $w_{j1}$  entre a camada de entrada e a camada escondida, calcula-se a derivada pela regra da cadeia,

$$\frac{\partial E}{\partial w_{\tilde{j}1}} = \sum_{p=1}^P \sum_{l=1}^{n_L} \frac{\partial E_p}{\partial S_{pl,L}} \frac{\partial S_{pl,L}}{\partial \lambda_{pl,L}} \frac{\partial \lambda_{pl,L}}{\partial S_{pj,2}} \frac{\partial S_{pj,2}}{\partial \lambda_{pj,2}} \frac{\partial \lambda_{pj,2}}{\partial w_{\tilde{j}1}} =$$

$$\sum_{p=1}^P \left( \sum_{l=1}^{n_L} (S_{pl,L} - t_{pl}) f'(\lambda_{pl,L}) w_{\tilde{j}2} \right) f'(\lambda_{pj,2}) S_{p1} \quad (\text{B.5})$$

Para os *bias*,  $\theta_{j,2}$ , da camada escondida, também pela regra da cadeia generalizada, tem-se,

$$\frac{\partial E}{\partial \theta_{j,2}} = \sum_{p=1}^P \sum_{l=1}^{n_L} \frac{\partial E_p}{\partial S_{pl,L}} \frac{\partial S_{pl,L}}{\partial \lambda_{pl,L}} \frac{\partial \lambda_{pl,L}}{\partial S_{pj,2}} \frac{\partial S_{pj,2}}{\partial \lambda_{pj,2}} \frac{\partial \lambda_{pj,2}}{\partial \theta_{j,2}} =$$

$$\sum_{p=1}^P \left( \sum_{l=1}^{n_L} (S_{pl,L} - t_{pl}) f'(\lambda_{pl,L}) w_{\tilde{j}2} \right) f'(\lambda_{pj,2}) \quad (\text{B.6})$$

A derivada  $f'(x)$  - onde  $x$  aqui representa uma variável qualquer e  $f$  é a função *sigmoidal*, é fornecida por:

$$f'(x) = \frac{e^{-x}}{(1+e^{-x})^2} = f(x)(1-f(x)) \quad (\text{B.7})$$

## ANEXO C

## ALGORITMO DO CONTROLE PREDITIVO UTILIZANDO REDES NEURAIAS

Neste Anexo é apresentado um algoritmo para implementação do Controlador Preditivo com Modelo utilizando as Redes Neurais Artificiais para representarem o modelo interno do controlador.

1. Amostrarm  $y_i(k)$  e variáveis secundárias  $u_i(k)$ , sendo  $u=x(k)-x(k-1)$ , e normalizar estas variáveis, utilizando a Equação 3.19;
2. Fazer predições de  $\hat{y}_i(k+1)$  via RNA, onde  $\hat{y}_i$  corresponde ao valor predito de  $y_i$ , utilizando o modelo interno que foi desenvolvido baseado na Equação 3.27;
3. Avaliar o mínimo da função objetivo em função de  $\hat{y}$ , *setpoint* e  $u$ , utilizando a Equação 3.28, de forma a atender também aos critérios de restrição das Equações 3.29, 3.30 e 3.31. Ao invés de se utilizar os valores de *setpoints* diretamente na equação 3.28, foi empregado a estratégia de se utilizar uma trajetória de referência calculada em função dos valores atuais das variáveis  $y(k)$  e *setpoints* utilizando a Equação 3.33. Dentro dessa estratégia foi realizado o cálculo de  $y$  predito de acordo com a Equação 3.35;
4. Atingiu o critério de convergência (atingiu o mínimo)?

Obs.: essa rotina foi realizada baseada no método de programação quadrática sucessiva existente na rotina interna do Fortran.

N → corrigir  $u'$  e voltar para 2;

S → efetuar a desnormalização nas variáveis de saída do controlador, utilizando a Equação 3.20 e implementar a primeira ação de controle →  $u_1' = u$ ;

5. Esperar hora de amostragem;
6. Voltar para etapa 1.

## ANEXO D

## MODELO DINÂMICO DO CONVERSOR

A simulação do processo de Craqueamento Catalítico foi desenvolvida a partir das características do Conversor FCC da Refinaria Henrique Lage, baseando-se em balanços de massa e energia. Este modelo, denominado aqui de modelo fenomenológico e algumas vezes de modelo rigoroso, já havia sido previamente validado com os dados da unidade industrial (MORO, 1992), tendo apresentado resultados bastante satisfatórios, sendo inclusive proposto sua implantação para controle na unidade, utilizando controlador DMC. Este modelo fenomenológico, sem ação do controlador, foi utilizado para gerar os conjuntos de dados de treinamento das redes neurais e também para representar a unidade industrial para implementação de um controle preditivo.

A seguir serão apresentadas as equações obtidas destes balanços, obtidas por MORO, (1992), que representam o modelo fenomenológico a ser usado neste estudo para simular o conversor:

- *Balanço de carbono no catalisador do regenerador* – este carbono é também conhecido como carbono catalítico e é representado por,

$$Hra \frac{dCcat}{dt} = -Rrc.Ccat + 100.Rcf \quad (D.1)$$

onde:  $Hra$  = inventário de catalisador no reator (ton.)

$Ccat$  = carbono catalítico (%massa)

$Rrc$  = circulação de catalisador para o Riser (ton/tmin)

$Rcf$ , por sua vez, representa o carbono reativo e é obtido pela seguinte equação em estado estacionário,

$$Rcf = \frac{Kcc.Pra.[C/O]^{0,65}}{Ccat.Crc^{0,06}} WHSV^{0,35} Exp(-1500/R/[Trx + 273]).Rtf.Dtf / 1440 \quad (D.2)$$

onde:  $Kcc$  = constante experimental;

$C/O$  = relação entre a circulação de catalisador e a vazão de carga; conhecida como relação catalisador / óleo (ton/ton);

$Trx$  = temperatura na saída do Riser ( $^{\circ}C$ );

$Rtf$  = vazão de carga ( $m^3/dia$ );

$Dtf$  = massa específica da carga ( $ton/m^3$ );

$Pra$  = pressão na zona de reação ( $kgf/cm^2$ );

$WHSV$  = velocidade espacial ( $ton_{carga}/h/ton_{catalisador}$ );

$Crc$  = teor de carbono no catalisador regenerado (%massa).

O catalisador gasto – representado pelo catalisador que deixa o vaso separador, por sua vez, é dado por,

$$Hra \frac{dCsc}{dt} = Rrc.(Crc2 - Csc) + 100.Rcf \quad (D.3)$$

onde:  $Csc$  = teor de carbono no catalisador gasto (%massa);

$Crc2$  = teor de carbono no catalisador regenerado (%massa);

- *Balço de energia no Riser* – considerado como um reator CSTR, foi obtida a seguinte equação,

$$Hris.Sc. \frac{dTrx}{dt} = Sc.Rrc.(Trg2 - Trx) + Sf.Dtf.Rtf.(Tfp - Trx)/1440 + \\ - \Delta Hfv.Dtf/1440 - \Delta Hcr.Roc \quad (D.4)$$

onde:  $Hris$  = inventário de catalisador no Riser (ton);

$Sc$  = calor específico do catalisador, constante ( $kcal/kg/^{\circ}C$ );

$Trg2$  = temperatura do leito do segundo estágio de regeneração ( $^{\circ}C$ );

$S_f$  = calor específico da carga, constante e igual ao dos produtos  
(kcal/kg<sup>o</sup>C);

$T_{fp}$  = temperatura da carga na entrada do Riser (°C);

$\Delta H_{fv}$  = calor de vaporização da carga (kcal/kg);

$\Delta H_{cr}$  = calor de craqueamento (kcal/kg);

$R_{oc}$  = velocidade das reações de craqueamento (ton/min).

A velocidade das reações de craqueamento pode ser obtida por,

$$R_{oc} = k_{cr} \cdot \frac{A}{(1-A)} \cdot R_{tf} \cdot \frac{D_{tf}}{1440}, \quad (D.5)$$

onde  $k_{cr}$  é uma constante obtida experimentalmente e  $A$  representa a severidade, sendo definida pela equação:

$$A = 4040 \cdot \frac{P_{ra} \cdot (C/O)^{0,65} \cdot W_{HSV}^{0,35}}{C_{cat} \cdot C_{rc}^{0,06}} \cdot \text{Exp} \left( - \frac{15000}{R \cdot (T_{rx} + 273)} \right) \quad (D.6)$$

Na verdade, (MORO, 1995), a severidade da reação catalítica é determinada a partir da expressão:

$$SEVCONT = 100 \cdot A / (1.0 + A) \quad (D.6a)$$

A fração mássica da carga convertida pode ser obtida por,

$$\text{Conversão (\%m)} = \frac{R_{oc}}{1440 \cdot R_{tf} \cdot D_{tf}} \quad (D.7)$$

- *Balanço de catalisador no vaso separador* – é obtido por,

$$\frac{dHra}{dt} = Rcr - Rsc, \quad (D.8)$$

onde a vazão de catalisador gasto é manipulada por uma válvula situada no *stand-pipe*, controlada pelo controlador de nível do vaso separador. A vazão de catalisador depende do diferencial de pressão disponível para a válvula, que por sua vez, depende das pressões do reator e do regenerador e do nível do leito de catalisador, e pode ser escrita como,

$$\Delta P_{LCV} = Pra + \gamma h + \gamma hsp - Prg \quad (D.9)$$

onde:  $\Delta P_{LCV}$  = perda de carga disponível para a válvula;

$Pra$  = pressão no vaso separador;

$\gamma$  = peso específico do catalisador fluidizado (assumido = 500kgf/m<sup>3</sup>);

$hsp$  = altura do *stand-pipe* (m);

$Prg$  = pressão do regenerador;

A altura de catalisador no vaso separador  $h$ , é dada por,

$$h = \left( \frac{Hra}{\rho \cdot A} \right) \cdot 1000 \quad (D.10)$$

onde:  $\rho$  = massa específica do catalisador no vaso separador (= 500kg/m<sup>3</sup>);

$A$  = área transversal do vaso separador (m<sup>2</sup>).

A vazão de catalisador através da válvula é, portanto,

$$R_{sc} = CV_{LCV} \cdot A_{LCV} \cdot (\Delta P_{LCV})^{0,5} \quad (D.11)$$

onde:  $A_{LCV}$  = abertura da válvula;

$CV_{LCV}$  = coeficiente de vazão.

A dinâmica desta válvula, assim como de todas as outras, foi considerada de primeira ordem; então,

$$\tau_{LCV} \frac{dA_{LCV}}{dt} = C \cdot A_{LCV} \quad (D.12)$$

onde:  $C$  = saída do controlador do vaso separador.

- *Balanço de energia no vaso separador* – considera apenas a capacidade térmica do catalisador, desprezando o efeito do vapor e hidrocarbonetos.

$$H_{ra} \cdot \frac{dT_{ra}}{dt} = R_{rc} \cdot T_{rx} - R_{sc} \cdot T_{ra} \quad (D.13)$$

- *Balanço de energia no leito do primeiro estágio do regenerador* – o regenerador é considerado um reator de mistura, com temperatura e concentrações homogêneas, calores específicos constantes na faixa de temperatura normal e considerando também que 10% do ar é arrastado para o segundo estágio, e é aquecida até a temperatura do leito mas não participa da reação de queima de coque. A equação obtida é,

$$\begin{aligned} H_{rg1} \cdot S_c \cdot \frac{dT_{rg1}}{dt} = & S_c \cdot R_{sc} \cdot T_{ra} - S_c \cdot R_{rc1} \cdot T_{rg1} + \\ & + 0,0215 \cdot S_a \cdot R_{ai1} \cdot (T_{ai} - T_{rg1}) + \\ & - F_{gk1} \cdot S_a \cdot T_{rg1} / 1000 - \Delta H_{rg1} \cdot C_{arb1} \cdot 12 / 1000 \end{aligned} \quad (D.14)$$

onde:  $S_a$  = calor específico do ar e dos gases de combustão (kcal/kg°C);

$Rai1$  = vazão de ar injetada no primeiro estágio de regeneração ( $k Nm^3/h$ );

$Tai$  = temperatura do ar injetado ( $^{\circ}C$ );

$Far12$  = vazão de ar arrastada para o segundo estágio, proporcional à vazão de catalisador ( $\approx 10\%$ );

$Fgk1$  = vazão de gases de combustão ( $kgmol/min$ );

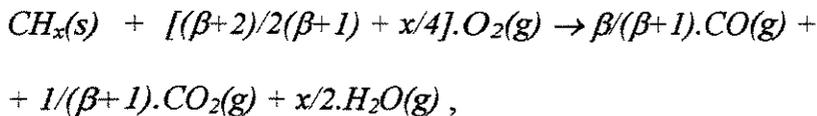
$Carb1$  = carbono queimado ( $kgmol/min$ );

$\Delta Hrg1$  = calor de combustão do coque, considerado função apenas da relação  $CO_2/CO$  nos gases de combustão, sendo obtido a partir de,

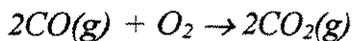
$$\Delta Hrg1 = \left( 7831 + \frac{5416}{(CO_2/CO)} \right) / \left( 1 + \frac{1}{(CO_2/CO)} \right) \quad (D.15)$$

onde esta equação considera apenas a queima de carbono grafite, desprezando o hidrogênio, enxofre, etc.

A queima de coque na fase densa é representada pela reação:



sendo que, na fase diluída, ocorre a reação,



onde:  $CH_x$  = coque depositado no catalisador;

$\beta$  = relação  $CO_2/CO$  intrínseca no catalisador (mol/mol).

A velocidade de queima de carbono é representada por,

$$r_C = -K_{CO} \cdot e^{-E_C/R.T} \cdot C_C \cdot P_{O_2} \quad (D.16)$$

onde:  $K_{CO}$  = constante pré-exponencial ( $\text{kPa}^{-1} \cdot \text{s}^{-1}$ );

$$E_C/R = 18.900\text{K};$$

$C_C$  = kg carbono/kg de catalisador;

$P_{O_2}$  = pressão parcial média logarítmica de  $O_2$  ao longo do leito (kPa);

No trabalho de Moro foi utilizado uma equação aproximada para representar a velocidade de queima de coque, dada por,

$$R_{cb1} = K_{or} \cdot \exp(-18.900/(T_{rg1} + 273)) \cdot C_{rc1} \cdot O_{fg1} \cdot P_{rg} \quad (D.17)$$

onde:  $R_{cb1}$  = velocidade de queima de coque (%C/min);

$C_{rc1}$  = teor de carbono no catalisador do 1º estágio (%massa);

$O_{fg1}$  = teor de  $O_2$  no gás de combustão do 1º estágio (%vol);

$P_{rg}$  = pressão do regenerador ( $\text{kgf/cm}^2$ );

$Carb1$  = queima de carbono em  $\text{kgmol/min}$ , dada por:

$$Carb1 = 10/12 \cdot R_{cb1} \cdot H_{rg1}$$

- *Balanco de carbono no catalisador do Regenerador* – a equação que fornece a variação de carbono no catalisador do regenerador é:

$$\frac{dC_{rc1}}{dt} = \frac{(R_{sc} \cdot C_{sc} - R_{rc1} \cdot C_{rc1})}{H_{rg1} \cdot R_{cb1}} \quad (D.18)$$

- *Balanco de oxigênio nas fases densa e diluída* – o oxigênio no gás do leito do 1º estágio do regenerador é representado por,

$$\frac{Vde1 \cdot \rho^m}{100} \cdot \frac{dOfg1}{dt} = 0,21 \cdot R^mai1 \cdot FG^m \cdot \frac{Ofg1}{100} \cdot \frac{10}{12} \cdot Rcb1 \cdot Hrg1 \cdot Fat1 \quad (D.19)$$

onde:  $Vde1$  = volume da fase densa do 1º estágio ( $m^3$ );

$\rho^m$  = densidade molar dos gases de combustão ( $kgmol/m^3$ );

$R^mai1$  = vazão molar de ar, já descontado arraste para 2º estágio ( $kgmol/min$ );

$Ofg1$  = % molar de  $O_2$  nos gases de combustão na saída da fase densa;

$Fat1$  = relação molar  $O_2$  consumido/ $C$  queimado, fornecida por:

$$Fat1 = \frac{(\beta + 2)}{2 \cdot (\beta + 1)} + \frac{x}{4} \quad (D.20)$$

Estes cálculos são repetidos de maneira análoga para o 2º estágio de regeneração.

Na fase diluída do 1º estágio é utilizado a equação:

$$Rco = -k_{co} \cdot \exp\left[-\frac{15.000}{(Tdi1 + 273)}\right] \cdot [O_2]^{0,5} \cdot [CO] \cdot Prg^{1,5} \quad (D.21)$$

onde:  $Rco$  = em  $kgmol$  de  $CO/m^3 \cdot s$ ;

$[O_2]$  = % molar de  $O_2$  na fase diluída;

$[CO]$  = % molar de  $CO$  na fase diluída.

O balanço de massa para o  $O_2$  é dado por:

$$\frac{Vdi1 \cdot \rho^m}{100} \cdot \frac{d[O_2]}{dt} = FG^m \cdot \frac{(Ofg1 - [O_2])}{100} - \frac{Rco}{2 \cdot Vdi1 \cdot 60} \quad (D.22)$$

onde:  $V_{di1}$  = volume da fase diluída do 1º estágio ( $m^3$ ).

- *Balanço de Energia na fase diluída* – a equação que representa este balanço é,

$$\frac{dT_{di1}}{dt} = \frac{FG}{\rho \cdot V_{di1}} (T_{rg1} - T_{di1}) + 67636 \cdot \frac{R_{co.60}}{\rho \cdot Sa} \quad (D.23)$$

onde:  $T_{di1}$  = temperatura da fase diluída do 1º estágio ( $^{\circ}C$ );

$FG$  = vazão de gases de combustão ( $kg/min$ );

$\rho$  = densidade dos gases de combustão ( $kg/m^3$ ).

Cálculo análogo é feito para a fase diluída do 2º estágio e para a fase diluída geral.

- *Balanço de pressão no regenerador* – o balanço é feito considerando o regenerador como sendo apenas uma capacitância, de acordo com a equação,

$$V_{di1} \frac{d\rho}{dt} = F_i - F_o \quad (D.24)$$

onde:  $F_i$  = vazão de gases de combustão gerados ( $kg/min$ );

$F_o$  = vazão de gases de combustão enviados para a caldeira de  $CO$  ( $kg/min$ ).

Foi considerado comportamento de gás ideal, então,

$$\rho = \frac{P_{rg} \cdot PM}{R \cdot (T_{di1} + 273)}$$

onde:  $PM$  = peso molecular dos gases de combustão ( $kg/kgmol$ ).

Daí, tem-se,

$$V_{di1} \frac{PM}{R.(T_{di} + 273)} \cdot \frac{dPrg}{dt} = F_i - F_o \quad (D.25)$$

onde  $F_o$  é controlado pela válvula *slide* de gases de combustão sob comando do controlador de pressão diferencial entre o regenerador e o reator. Esta válvula foi simulada de maneira semelhante às válvulas de catalisador.

- *Balço de catalisador no leito do 1º estágio do regenerador* – o nível de catalisador no 1º estágio é dado por:

$$h = \frac{Hrg1}{\rho_{cat} \cdot Arg1} \quad (D.26)$$

onde:  $\rho_{cat}$  = massa específica média do leito do 1º estágio ( $\text{kg/m}^3$ );

$Arg1$  = área transversal do 1º estágio ( $\text{m}^2$ ).

A vazão é dada por:

$$Rrc1 = K.(h - hv)^{0.5} \quad (D.27)$$

onde:  $Rrc1$  = vazão de catalisador do primeiro para o segundo estágio (ton/min);

$hv$  = altura do vertedor (4 m).

O balanço de massa resulta em,

$$\frac{dHrg1}{dt} = Rsc - K.(h - hv)^{0.5} \quad (D.28)$$

## ANEXO E

## ALGORITMO DE IDENTIFICAÇÃO DO PROCESSO EM REDES NEURAS ARTIFICIAIS.

É descrito a seguir o procedimento utilizado para identificação do modelo fenomenológico utilizando as redes neurais artificiais (DE SOUZA JR. <sup>5</sup>, 1996).

- 1- Utilizando a rotina computacional referente ao programa do modelo fenomenológico, foram obtidos três conjuntos de dados das variáveis manipuladas e controladas, *grupo de treinamento*, *grupo de validação* e *grupo de teste*;
- 2- utilizando rede neural com esqueleto 5xHx4, foi obtida a primeira rede neural, fazendo  $H = 1$ , utilizando a primeira variável manipulada e as 4 variáveis controladas obtidas pela seqüência de treinamento em 1, *grupo de treinamento*;
- 3- utilizando a outra seqüência, *grupo de validação*, foi realizada a validação da rede treinada;  
  
caso 3 a: a rede não converge, voltar para 1 e alterar o número de padrões de treinamento, ou o tempo de amostragem;  
  
caso 3 b: a rede converge, mas apresenta desempenho ruim, alterar  $H$  e voltar para 2;  
  
caso 3 c: a rede converge, e apresenta bom desempenho na validação, testar a rede com a outra seqüência de dados, *grupo de teste*;
- caso 3 d: a rede converge, mas o tempo de treinamento gasto é excessivo para ser utilizado num sistema com arquitetura MIMO mais complexa, retornar para 1 e obter outra seqüência de padrões (*grupo de treinamento*, *grupo de validação* e *grupo de teste*);
- caso 3 e: a rede converge, apresenta valores aceitáveis em todos os dados referentes à rede, obter mais algumas arquiteturas aumentando o valor de  $H$ , mantendo constantes os demais parâmetros obtidos em 3 d, para efetuar comparações de desempenho;

---

<sup>5</sup> DE SOUZA JR., M. B. *Estudo Preliminar da teoria das ANN. Subrotinas OPTCG.FOR, OPTMU.FOR, MODTRAIN.FOR.* Revisão das subrotinas. Universidade Federal de Pernambuco – UFPE. Departamento de Engenharia Química - DEQ Laboratório de Simulação e Controle de Processos - LSCP©. 1996. Informação verbal.

- 4- capturar informações obtidas em 3 e, como número de nós na camada escondida, critério de convergência, número de padrões de treinamento, tempo de treinamento, intervalo de tempo de amostragem, valor da função objetivo, número de degraus aplicados na variável manipulada;
- 5- repetir as ações retornando para 1, considerando a segunda variável manipulada, e assim sucessivamente até obter várias configurações de redes neurais para todas as variáveis manipuladas;
- 6- utilizando a rede neural com esqueleto  $8 \times H \times 4$ , fazendo  $H$  igual ao melhor valor obtido de  $H$  para cada variável manipulada em 5, testar diversas arquiteturas para comparações;
- 7- selecionar a arquitetura que obteve melhor desempenho e menor tempo de treinamento, para ser o modelo em redes neurais.

**APÊNDICES**

# V SBAI

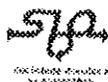
V SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE  
07 A 09 DE NOVEMBRO DE 2001  
HOTEL CONTINENTAL - CANELA, RS

## CERTIFICADO

CERTIFICO QUE WILLIAM GONÇALVES VIEIRA  
PARTICIPOU DO V SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE,  
REALIZADO DE 07 A 09 DE NOVEMBRO DE 2001 EM CANELA, RS.



DR. ALEXANDRE SANFELICE BAZANELLA  
PRESIDENTE DA COMISSÃO ORGANIZADORA



## IDENTIFICAÇÃO DE PROCESSO DE UMA UNIDADE DE CRAQUEAMENTO CATALÍTICO UTILIZANDO REDE NEURAL.

Vieira, W.G.<sup>1</sup>; Fileti, A.M.F.<sup>2\*</sup>; Carvalho, F.R.<sup>3</sup>

<sup>1</sup>CTEC/DEQ - Universidade Federal de Alagoas  
Maceió - AL - Brasil 57072-970 e-mail: [wgv@fapeal.br](mailto:wgv@fapeal.br)

<sup>2</sup>DESQ/FEQ - Universidade Estadual de Campinas  
Campinas - SP - Brasil 13083-970 e-mail: [frattini@desq.feq.unicamp.br](mailto:frattini@desq.feq.unicamp.br)

<sup>3</sup>CTG/DEQ - Universidade Federal de Pernambuco  
Recife - PE - Brasil 50740-521 e-mail: [florival@npd.ufpe.br](mailto:florival@npd.ufpe.br)

Este artigo descreve um procedimento de identificação, baseado em RNA, de um conversor Catalítico em Leito Fluido (FCC). Um modelo fenomenológico, validado com dados reais de operação, foi usado para gerar um conjunto de dados de variáveis operacionais. A partir do estado estacionário inicial foram aplicados vários degraus nas variáveis manipuladas sendo gerados três grupos de dados para treinamento, validação e teste da rede respectivamente. Uma rede neural multicamada feedforward foi escolhida para a representar a FCC, sendo adotadas diferentes estratégias para sua arquitetura: na primeira, a camada de entrada foi formada por uma variável manipulada, e na segunda, foi formada de quatro variáveis manipuladas. A camada de saída foi formada por quatro variáveis controladas. O número de nós na camada escondida foi obtido por tentativa-e-erro. Das diversas estruturas propostas, as arquiteturas escolhidas para representar o modelo da FCC foram 5x15x4 e 8x15x4 (IxHxO) com critério de convergência de  $10^{-3}$  no gradiente da função objetivo. Em todos os testes, o erro relativo das variáveis de saída foi inferior a 1%. Como resultado, foram desenvolvidos modelos em redes neurais confiáveis para a identificação de processo e eles poderão ser usados como modelo em uma estrutura de controle preditivo.

### INTRODUÇÃO

O uso de métodos matemáticos complexos e mais precisos em engenharia de sistemas tem sido extensivamente encorajado pela introdução de computadores digitais de baixo custo e alta velocidade de processamento. Esta nova tecnologia permitiu o uso de rede neural artificial como metodologia para a identificação e controle de sistemas químicos.

Qualquer processo químico linear ou não linear pode ser representado por um modelo em rede neural, mesmo quando os princípios termodinâmicos e cinéticos do processo são desconhecidos. Só os dados operacionais de entrada/saída são necessários [1].

Já foram feitas várias pesquisas baseadas em RNA: Narendra [2], resume a aplicação de RNA em Controle de Processo e descreve o último avanço nesta área. O autor compara as bases matemáticas das RNA e menciona algumas aplicações industriais de sucesso. Na área de identificação de processos, Nikraves [3] explica um procedimento de treinamento backpropagation que é aplicado em um reator CSTR.

De Souza Jr. [4] empregou uma RNA para classificação de processo onde a rede foi usada para prever as propriedades de um catalisador em função das condições de processo de fabricação. O autor também usa a rede para a identificação de reatores não lineares com controle preditivo. Santos [5] reporta a aplicação de uma RNA para identificação e controle de um processo FCC e usa dois modelos de processo diferentes: um modelo simplificado "side-by-side" e um mais complexo, já validado com os dados da unidade industrial. O estudo foi restrito a uma estrutura SISO (Single Input and Single Output).

---

\* Autor para o qual toda a correspondência deve ser enviada.

A unidade de FCC é um dos processos mais importantes em refinarias de petróleo devido ao grande volume de produtos processados, seu rendimento e alto valor agregado. Um pequeno benefício neste processo é economicamente atraente. Além disso, os regulamentos ambientais que restringem suas emissões poluentes como CO, CO<sub>2</sub>, NO<sub>x</sub> e SO<sub>x</sub>, tornaram este controle muito importante, e devido às características deste processo, pode ser necessário um controle avançado. Porém, as unidades de FCC apresentam processos fisicamente complexos e diversas dificuldades para operar e controlar. As seções do regenerador e do reator das unidades de FCC são altamente interativas e com dinâmica difícil. O processo é pouco conhecido principalmente por causa da complexidade das cinéticas químicas envolvidas. Na prática, as unidades de FCC são reguladas freqüentemente por meio de controladores PID padrões e também por ações de controle manuais baseado no conhecimento dos operadores das refinarias.

Uma estratégia de otimização não linear com restrição foi proposta por Ansari e Tade [6] e aplicada à unidade de FCC. Um modelo dinâmico não linear do processo da FCC era usado para a análise da dinâmica da planta e para testes de um sistema de controle não linear multivariável. O modelo foi testado em uma aplicação em tempo real e os resultados foram usados para suprir os valores iniciais de projeto do sistema de controle não linear. Um algoritmo dinâmico de atualização de parâmetros foi usado para reduzir o efeito de erros de modelagem atualizando regularmente os parâmetros do modelo. O algoritmo de otimização não linear com restrição foi testado em tempo real no conjunto reator-regenerador da unidade FCC. Os resultados concordaram favoravelmente aos resultados de um controlador multivariável linear.

Wang et al. [7,8] propuseram um estudo usando funções “wavelets” e redes neurais não supervisionada para extração das características da dinâmica transiente e identificação do estado operacional do processo da FCC. Esta ação conjunta se propôs a reduzir a extensão dos dados e remover os componentes ruidosos do processo. Aguilara et al. [9] utilizaram um projeto de controle regulatório para estabilização das temperaturas do reator e do regenerador de uma unidade de FCC, considerando as condições de cinéticas pouco conhecidas. A lei de controle proposta usa estimativas on-line de erros de modelagem de entrada/saída, obtidas através de um observador proporcional-integral de ordem reduzida. A estrutura do controlador proposta é semelhante a um compensador proporcional - duplo integral (PI<sup>2</sup>) com a nova parametrização do ganho do controlador sendo determinada em termos da malha fechada e constantes de tempo estimadas. O desempenho do esquema de controle proposto foi analisado por simulações numéricas. Antoniaades e Christofides [10] propuseram uma metodologia para a síntese de controladores não lineares de realimentação para sistemas SISO não linear “Differential Difference Equation” (DDE) que incluem retardo de tempo no atuador de controle e no sensor de medida. O método de controle proposto foi aplicado com sucesso a uma unidade FCC onde foi mostrado que o desempenho do controlador não linear proposto não é afetado pela presença de tempo morto associada à malha de reciclo e aos dutos que transferem material do reator para o regenerador e vice-versa.

Zanin et al. [11] descreveu a implementação de uma nova estratégia de otimização não convencional em tempo real aplicada na maximização da saída de LPG em um conversor FCC da refinaria de São José dos Campos no Brasil. Foi dado enfoque às dificuldades de otimização para os controladores existentes. Os primeiros testes efetuados foram descritos em detalhes. Eles mostraram que os benefícios da otimização não são restritos a fatores econômicos. A implementação da estratégia fornece meios de como mudar a forma de pensar dos operadores da unidade. A estratégia de otimização

implementada mostrou ser capaz de manter o controle da planta até mesmo na ausência do sinal de algumas variáveis manipuladas e na presença de fortes perturbações. Além disso, foi mostrado que a estratégia de otimização pode direcionar o processo para novos pontos operacionais. Sarma e Rengaswamy [12] usaram uma rede de controladores de lógica fuzzy (GS-FLCs), usando padrão sigmoidal (SGS). Esta estrutura não linear GS-FLC permite o uso de um desacoplador estático linear bastante simples (SLD). Esta técnica de controle foi aplicada em uma unidade de FCC, e o sistema multivariável GS-FLC/SLD demonstrou um bom desempenho de controle servindo como servo/regulatório e apresentando robustez.

Do exposto acima, o problema de controle da unidade FCC tem sido amplamente abordado por várias metodologias. A identificação baseada em redes neurais pode fornecer ao projetista desta unidade um melhor entendimento da dinâmica do processo podendo ser útil como um modelo interno para um Controle Preditivo. O Modelo de Controle Preditivo é baseado em um índice de desempenho global com parametrização das variáveis de controle em um modelo não linear, com inclusão de algumas restrições de processo [13,14,15]. O processo da FCC representa um desafio onde benefícios significativos para indústria de processo e para teoria de controle poderiam ser alcançados.

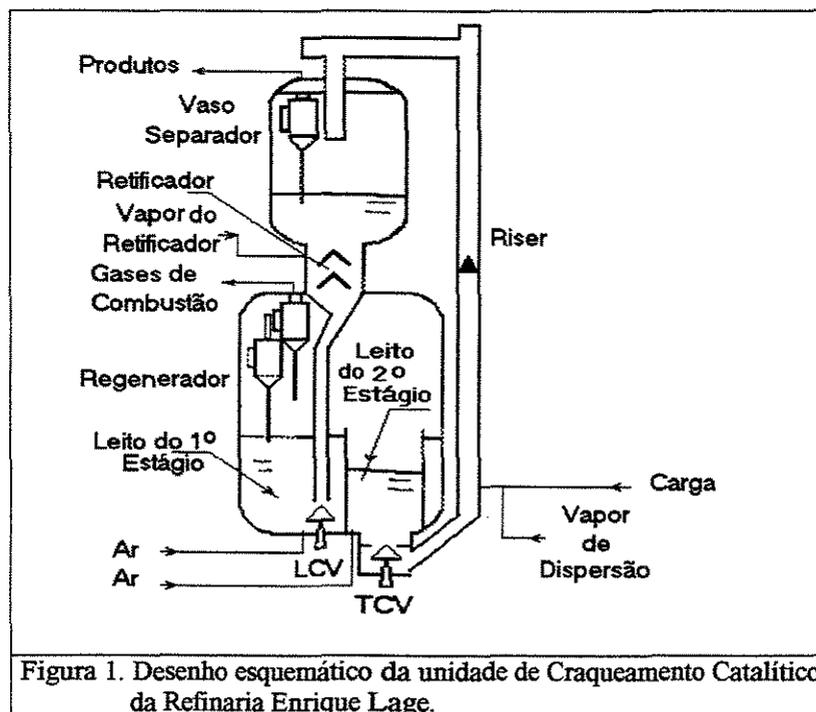
Neste trabalho é descrito o desenvolvimento de um modelo FCC usando RNA. Este modelo representa um processo fortemente não linear, com restrições operacionais caracterizando um sistema MIMO (Multiple Input and Multiple Output). Além da não linearidade do processo e das restrições operacionais, é observado alto grau de interação entre suas variáveis. O estudo de caso escolhido para o presente desenvolvimento foi a Unidade de Craqueamento Catalítico em Leito Fluido (FCC) da refinaria Henrique Lage - REVAP (São José dos Campos, SP, Brasil), através de seu respectivo modelo: Kellogg Orthoflow F. Moro [16] apresentou o modelo fenomenológico da Refinaria Henrique Lage da unidade FCC. Este modelo foi validado com os dados operacionais da unidade industrial. Para treinar a RNA, um simulador numérico baseado neste modelo fenomenológico foi usado no presente estudo para gerar um conjunto de dados de variáveis operacionais. São propostas diferentes arquiteturas de redes para representar o processo da FCC.

## DESCRIÇÃO DO PROCESSO

O processo escolhido para estudo foi o do conversor (FCC) representado pelo modelo Kellogg Orthoflow F. da Unidade de Craqueamento Catalítico da Refinaria Henrique Lages da Petrobrás. O objetivo é reduzir o tamanho das redes hidrocarbônicas das frações mais pesadas do Petróleo por meio de reações catalíticas. Este processo é extremamente útil pois transforma produtos derivados de Petróleo de alto peso molecular e baixo valor comercial agregado em produtos de maior valor comercial. A Unidade de Craqueamento recebe como carga as correntes provenientes das seguintes unidades: Destilação à Vácuo, como Gasóleo e Resíduo de Vácuo, Unidade de Desasfaltação com Propano, como Óleo Desasfaltado. Como produtos gerados, tem-se: Gás Combustível; Gás Liquefeito de Petróleo (GLP); Nafta Craqueada; Óleo Leve de Reciclo (Light Cycle Oil-LCO); Óleo Decantado também denominado Óleo Combustível de FCC ou Óleo Combustível Craqueado e Coque. Desses produtos, o que apresenta maior valor agregado é a Nafta Craqueada, utilizada como gasolina automotiva, sendo portanto esta a principal meta de uma unidade de craqueamento. O processo ocorre à temperaturas elevadas, na faixa de 500 a 550°C, em presença de um catalisador seletivo, à base de Zeólitas. O

catalisador se apresenta na forma de um pó branco de elevada porosidade e área específica, e, por apresentar dimensões tão pequenas, escoar como se fosse um fluido, o que facilita seu manuseio. Devido às condições de temperatura do reator, ocorrem também reações secundárias indesejáveis, como formação de coque, polimerização e desidrogenação, com conseqüente deposição sobre a superfície do catalisador, reduzindo sua atividade.

A unidade é composta de duas seções, uma de reação catalítica, onde ocorrem as reações de quebra de cadeia e também deposição de coque sobre o catalisador, e a outra onde ocorrem as reações de queima do coque, regenerando o catalisador (vide FIGURA 1). Desta forma o catalisador é circulado da seção de reação para a seção de regeneração, retornando para a seção de reação (vide FIGURA 2). A reação de regeneração é feita por queima com injeção de ar no regenerador. Devido às condições extremamente severas de operação, há necessidade de controle rigoroso de algumas variáveis operacionais (controladas), o que é feito direta ou indiretamente por meio de alterações em outras variáveis do processo (manipuladas). Diversas variáveis podem ser usadas como controle na indústria. Neste estudo serão usadas as seguintes variáveis: temperatura de saída do reator (riser) – TRX; temperaturas das fases densas do primeiro e segundo estágios de regeneração – TRG1 e TRG2; e conversão do reator – Severidade. As seguintes variáveis serão manipuladas: vazão da carga – RTF, vazão de catalisador regenerado – CTCV, vazão de ar para o regenerador – RAI e temperatura da carga – TFP. Além dessas variáveis, também se deseja manter outras variáveis do processo dentro de seus limites de restrição: diferencial de pressão entre regenerador e conversor, temperatura da fase diluída do 2º estágio do regenerador e temperatura da fase diluída geral.



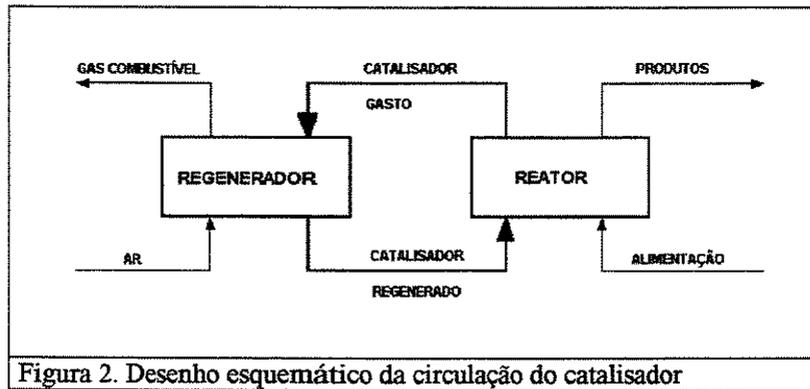


Figura 2. Desenho esquemático da circulação do catalisador

## METODOLOGIA

### Redes neurais

A RNA é formada por elementos processadores denominados de neurônios, nós ou nodos, interligados por canais chamados de conexões formando uma rede densa [4, 17]. Os nodos são organizados em camadas que unem a entrada com a saída. As conexões interligam os nodos de uma camada com os nodos de outra. O modo como os nodos são conectados e a disposição deles determina a arquitetura da rede. No presente estudo a rede foi configurada como multicamada totalmente “feedforward”, com uma camada escondida e sem conexões de realimentação. As camadas escondidas são usadas para extrair da rede, resultados estatísticos de alta ordem [17].

Matematicamente, o comportamento de um neurônio em uma camada genérica pode ser representado por:

$$\lambda_{pj,k+1} = \left[ \sum_{i=1}^{n_k} w_{jik} \cdot S_{pi,k} \right] + \theta_{j,k+1} \quad (1)$$

onde:  $\lambda$  representa a saída do neurônio 'j', na camada 'k+1';

$S$  corresponde às saídas ou ativações de todos os neurônios da camada 'k';

$w$  é o peso das conexões;

$\theta$  é o limite interno de ativação do neurônio correspondente 'j' (bias).

Uma função de ativação, chamada de função de transferência do neurônio, é aplicada a  $\lambda$ . No presente estudo foi usada a função sigmoideal, definida por:

$$f(\lambda_{pj,k+1}) = \left[ 1 + \exp(-\lambda_{pj,k+1}) \right]^{-1} \quad (2)$$

O procedimento de aprendizagem é o processo onde os pesos e bias são modificados [18]. O treinamento supervisionado foi usado neste trabalho. Dados conhecidos de entrada e saída (padrões) são apresentados à rede. Então a rede é ajustada mudando os pesos e bias de acordo com regras predefinidas. Os padrões foram inicialmente normalizados para evitar diferenças de magnitude nos dados de entrada e saída [19].

Devido ao uso da função sigmoïdal como função de transferência, a normalização foi feita para obter os padrões no intervalo positivo entre 0.0 e 1.0. Na realidade, foi escolhido um limite de intervalo entre 0.1 e 0.9 para permitir, se necessário pequenas extrapolações [5]. A seguinte expressão foi usada para o procedimento de normalização:

$$P_{nor} = 0.1 + \left( \frac{P_{real} - P_{min}}{P_{max} - P_{min}} \right) \times 0.8 \quad (3)$$

onde:  $P_{nor}$  representa o padrão normalizado;

$P_{real}$  é padrão nas unidades de entrada/saída e é obtido do modelo fenomenológico;

$P_{min}$  é o limite inferior da variável;

$P_{max}$  é o limite superior da variável.

Os pesos e bias iniciais foram selecionados por uma rotina geradora de números aleatórios entre -1.0 e +1.0. O Algoritmo de Treinamento usado foi o Backpropagation, baseado na técnica de correção de erro. No processo de otimização foi usada a estratégia de "steepest descent" [4, 17].

## OBTENÇÃO DO CONJUNTO DE DADOS

O modelo fenomenológico desenvolvido por Moro [16] que representa a unidade de FCC foi usado para gerar os dados de processo para treinamento e teste do modelo em rede neural.

Fazendo uso de simulações numéricas baseado no modelo fenomenológico, primeiramente foi obtido um estado estacionário inicial. Então, vários degraus foram aplicados nas variáveis manipuladas sendo monitoradas as respostas nas variáveis controladas. Foi observado que o tempo gasto em treinamento da rede é diretamente dependente do número de degraus aplicados à variável manipulada. Por outro lado, um número muito baixo de degraus poderia ser insuficiente para representar toda faixa operacional do processo. Na realidade, deve haver um compromisso entre o número de degraus a serem implementados e a variação total permitida às variáveis manipuladas. Foi usado inicialmente o range recomendado por Moro: 1,5 kNm<sup>3</sup>/h na variável RAI; 0,003 unidades na variável CTCV; 50,0 m<sup>3</sup>/d na variável RTF e 2,2 °C na variável TFP. O intervalo de tempo entre dois degraus consecutivos deveria ser suficientemente grande para o processo atingir um novo estado estacionário antes da implementação do degrau seguinte. A Tabela 1 apresenta as variáveis manipuladas, os respectivos degraus impostos e o intervalo de tempo entre eles.

Tabela 1. Variáveis manipuladas, e suas respectivas perturbações impostas.

Variáveis manipuladas	CONJUNTO DE TREINAMENTO E VALIDAÇÃO			CONJUNTO DE TESTE	
	Degrau (%)	Tempo (min.)			Degrau (%)
<b>CTCV</b>	-7,-12,-5,+2,+11,+4, 0	270,300,300,300,600,600,300	+2,5; -2,5; 0	320, 350, 350	
<b>RAI</b>	-5, -9, -3, +1, +4, 0	570, 600, 900, 600, 600, 300	+2,5; -2,5; 0	320, 350, 350	
<b>RTF</b>	-6, -10, -4, +2, +7, 0	270, 300, 300, 300, 300, 300	+1,5; -1,5; 0	320, 350, 350	
<b>TFP</b>	-5, -8,5, -3, +1, +4, 0	270, 300, 300, 300, 300, 300	+2,5; -2,5; 0	320, 350, 350	
<b>CTCV;</b>	-7,-12,-5,+2,+11, +4, 0,	270, 300, 300, 300, 600,600,300,	+2,5; -2,5; 0;	320, 350, 350,	
<b>RAI;</b>	-5, -9, -3, +1, +4, 0,	600, 600, 900, 600, 600, 300,	+2,5; -2,5; 0;	350, 350, 350,	
<b>RTF;</b>	-6, -10, -4, +2, +7, 0,	300, 300, 300, 300, 300, 300,	+1,5; -1,5; 0;	350, 350, 350,	
<b>TFP</b>	-5, -8,5, -3, +1, +4, 0	300, 300, 300, 300, 300, 300	+2,5; -2,5; 0	350, 350, 350	

Os dados obtidos do modelo fenomenológico foram divididos em 3 grupos: treinamento (se estes valores forem usados para o procedimento de aprendizado), validação (se usado para validação da rede treinada) e teste (se usado para teste final da rede neural). Estes grupos de dados foram obtidos sob condições específicas, ou seja:

- Treinamento: tiradas amostras a cada 6 min., começando no 4º minuto; intervalo entre dois degraus sucessivos (veja Tabela. 1).
- Validação: tiradas amostras a cada 2 min., começando no 4º minuto; intervalo entre dois degraus sucessivos (veja Tabela. 1).
- Teste: tiradas amostras a cada 1 min., começando no 1º minuto; intervalo entre dois degraus sucessivos (veja Tabela. 1).

Todos estes dados foram obtidos depois de atingido o estado estacionário inicial (30min.).

Convém notar que a seqüência de degraus no teste é diferente da seqüência de degraus imposta para treinamento e da seqüência de validação.

## TREINAMENTO DA RNA

Com os conjuntos de dados obtidos de simulações numéricas rigorosas, inicia-se o procedimento de aprendizagem. Uma rede multicamada feedforward completamente conectada foi escolhida para a representação da FCC. Foram adotadas duas estruturas diferentes para a arquitetura de rede: na primeira, a camada de entrada era formada por uma variável manipulada e quatro variáveis controladas, e na segunda estrutura por quatro variáveis manipuladas e quatro controladas. A camada de saída foi formada pelas quatro variáveis controladas.

O número de nodos na camada escondida foi obtido por um procedimento de tentativa-e-erro. Observou-se que o aumento do número de nodos na camada escondida resultava em melhores resultados e tempo de treinamento inferior ao requerido com o aumento do número de camadas escondidas. Hiecht-Nielsen [20] já havia provado que qualquer função contínua pode ser simulada com uma arquitetura de 3 camadas. Entretanto, deve haver neurônios suficientes na camada escondida. Então o uso de mais de uma camada escondida foi descartado.

Uma vez determinado a arquitetura de rede, foi feito um estudo visando definir o número mínimo de padrões a ser apresentado à rede durante o treinamento. Os dados foram escolhidos de forma a representar toda faixa operacional das variáveis.

Inicialmente um número excessivo de padrões de treinamento (mais de 5000) foi usado. A convergência só foi atingida quando este número foi reduzido para menos de 1500

padrões, dependendo da precisão e do número de nodos na camada escondida. O critério de convergência usado variou de  $10^{-9}$  a  $10^{-3}$  no gradiente da função objetivo. O número de nodos de 1, 2, 3, 4, 5, 6, 10, 15 e 20 foram testados na camada escondida. Um erro relativo inferior a 1% entre os resultados do modelo e os resultados da rede foi considerado suficiente para aceitação do procedimento de treinamento.

## RESULTADOS E CONCLUSÕES

### Modelagem em RNA

A Tabela 2 mostra o tempo de CPU gasto no procedimento de treinamento com um PC Pentium II 400 MHz. Também mostra o critério de convergência usado e o valor mínimo obtido para a função objetivo. Foram testadas ambas as estruturas descritas no item "Treinamento da RNA".

Tabela 2. Tempo de treinamento, precisão e função objetivo

Variável manipulada	Tempo de CPU (min)	Critério de convergência	Função objetivo
Primeira estrutura			
CTCV	320	8,49E-4	1,61E-1
RAI	685	6,86E-4	8,26E-2
RTF	356	7,81E-4	3,56E-2
TFP	1029	4,37E-4	2,07E-2
Segunda estrutura			
CTCV, RAI, RTF, TFP	2589	5,26E-4	1,09E-1

Após treinamento, foi executada a validação da rede com o conjunto de dados de validação. Foi utilizada outra seqüência de degraus. Após isso, foi realizado o teste final. Neste teste, na tentativa de simular as condições mais próximas da realidade de uma unidade industrial, foram adicionados ruídos randômicos a todos os sinais das variáveis controladas.

Com um número reduzido de nodos (1 a 5) e usando como critério de convergência de  $10^{-9}$  a  $10^{-3}$  no gradiente da função objetivo, a convergência não foi atingida ou algumas oscilações do processo não puderam ser capturadas em alguns testes o que poderia ser resultado de uma perda de generalidade. Aumentando o número de neurônios na camada escondida para 10, 15 e 20, os resultados foram considerados aceitáveis. Neste caso, para reduzir o tempo gasto no treinamento foi necessário uma mudança no critério de convergência para ( $10^{-3}$  e  $10^{-2}$ ). O número de padrões também foi reduzido (1000 padrões).

Nas Figuras 3 e 4 é apresentado o comportamento das variáveis controladas para três degraus na variável manipulada CTCV. Os valores são mostrados de uma forma comparativa entre saída da rede (com ruído) e modelo rigoroso. Foram usados arquitetura  $5 \times 15 \times 4$  e critério de convergência de  $10^{-3}$  no gradiente da função objetivo. Como pode ser observado, o erro relativo entre modelo rigoroso e rede praticamente desaparece para as variáveis TRG1 e TRG2. Para Severidade e TRX, os erros relativos foram aproximadamente 0.15% e 0.1%.

Foram também dados degraus nas variáveis RAI, RTF e TFP. O comportamento foi similar ao obtido anteriormente e o erro relativo entre modelo em redes neurais e modelo rigoroso obtidos com o conjunto de dados de teste é mostrado em forma de dispersão nas Figuras 5 a 10. Deve ser notado que a seqüência de degraus de teste é diferente da seqüência imposta para treinamento e validação da rede. Estas figuras mostram a proximidade entre os resultados do modelo em redes neurais e os resultados obtidos por simulação rigorosa.

a proximidade entre os resultados do modelo em redes neurais e os resultados obtidos por simulação rigorosa.

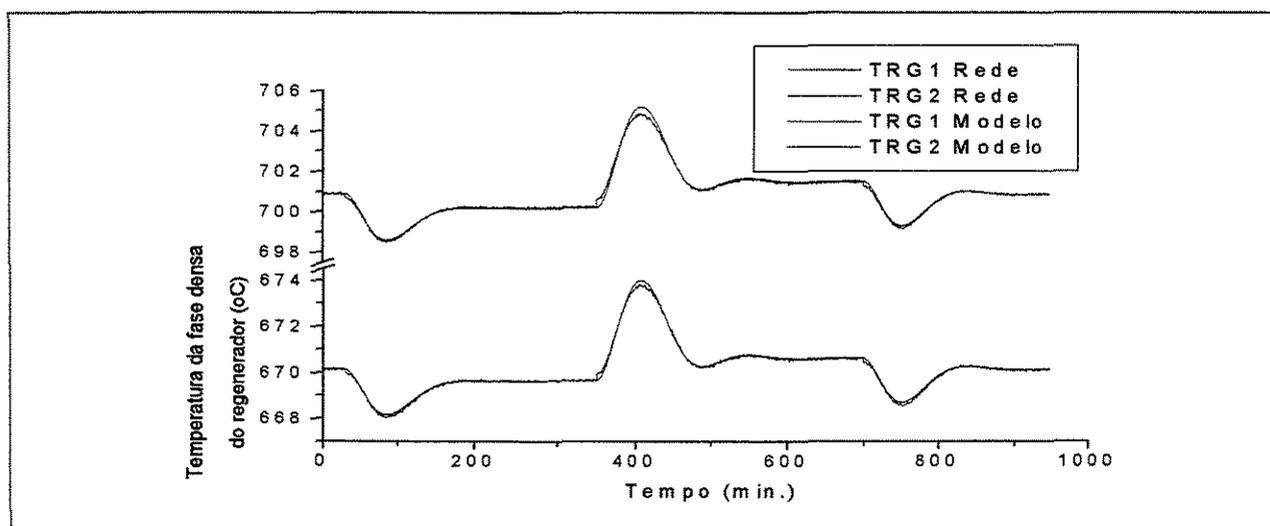


Figura 3. Resposta comparativa entre modelo rigoroso e modelo em rede neural para as variáveis TRG1 e TRG2 com 3 degraus na variável manipulada CTCV.

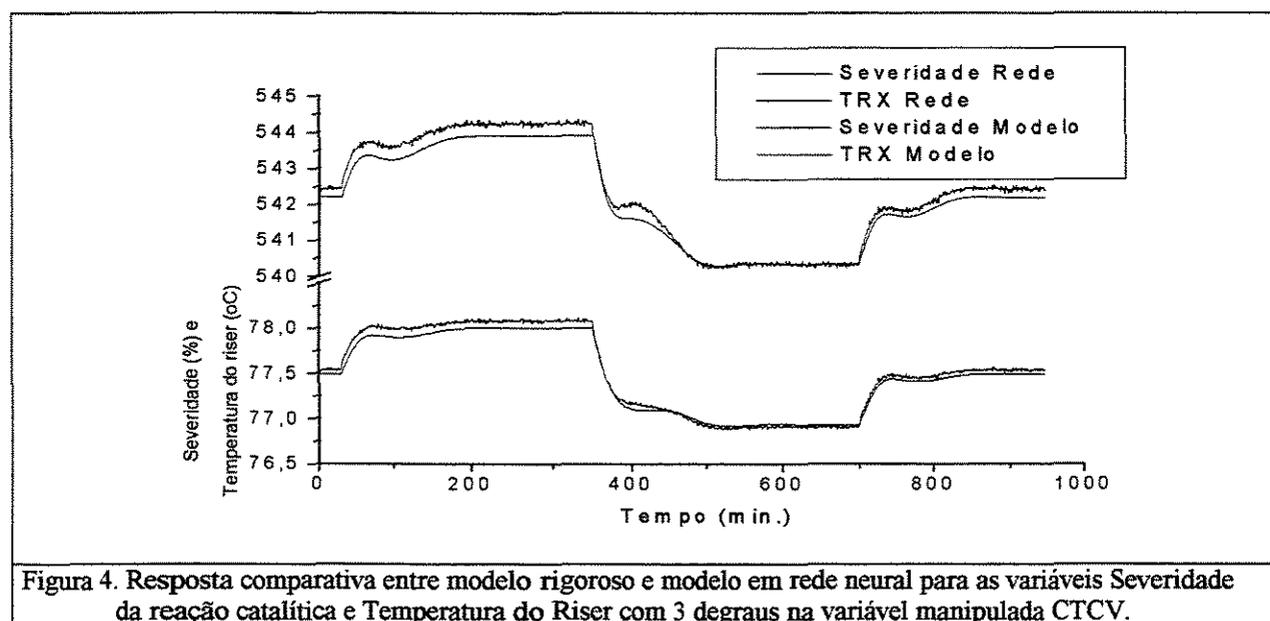
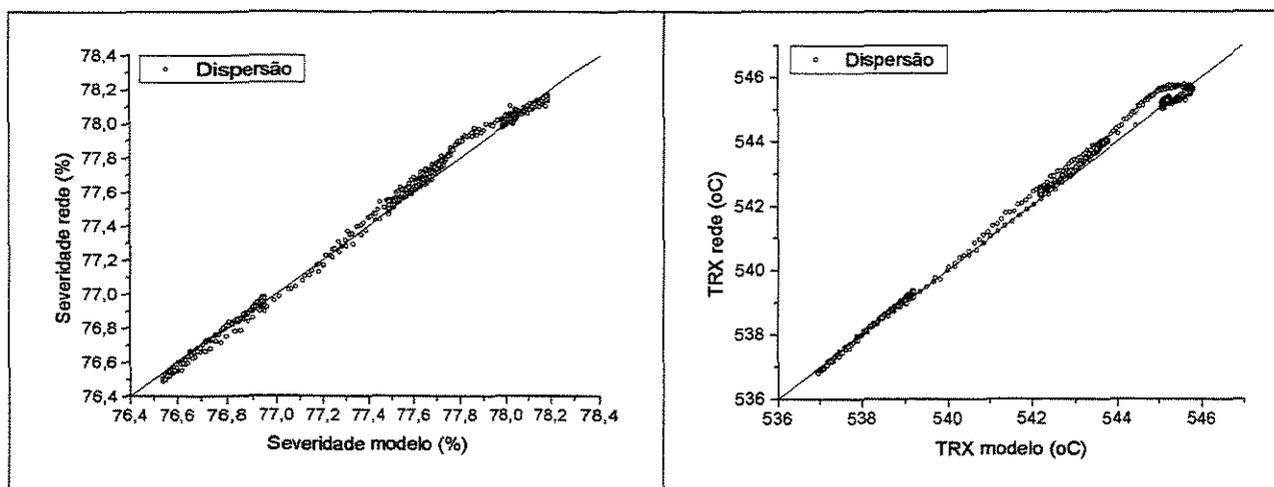
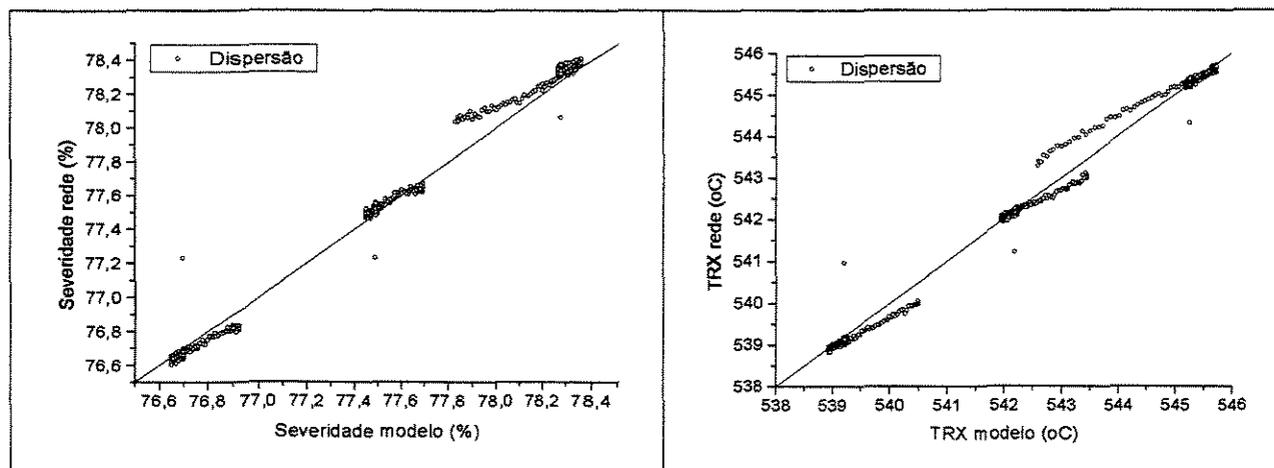


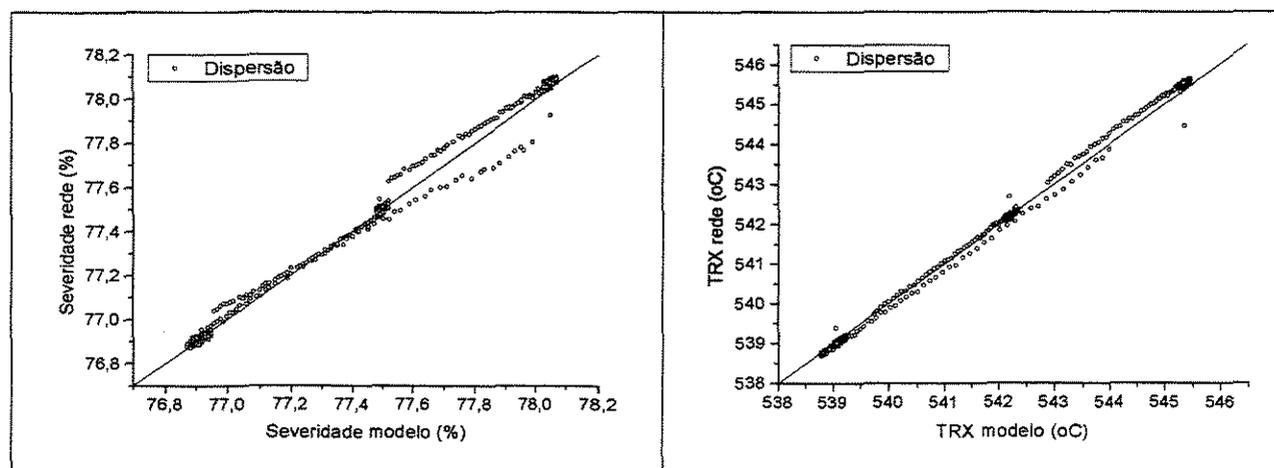
Figura 4. Resposta comparativa entre modelo rigoroso e modelo em rede neural para as variáveis Severidade da reação catalítica e Temperatura do Riser com 3 degraus na variável manipulada CTCV.



Figuras 5 e 6. Resposta da dispersão relativa entre modelo rigoroso e rede neural para variáveis Severidade da reação catalítica e TRX com 3 degraus na variável RAI.



Figuras 7 e 8. Resposta da dispersão relativa entre modelo rigoroso e rede neural para variáveis Severidade da reação catalítica e TRX com 3 degraus na variável RTF.



Figuras 9 e 10. Resposta da dispersão relativa entre modelo rigoroso e rede neural para variáveis Severidade da reação catalítica e TRX com 3 degraus na variável TFP.

Os resultados para a segunda estrutura da rede (arquitetura 8x15x4) com critério de convergência de  $10^{-3}$ , é apresentado na Figura 11 (Severidade da reação de

craqueamento). A diferença entre modelo fenomenológico e rede pode ser melhor observada nas Figuras 12 e 13.

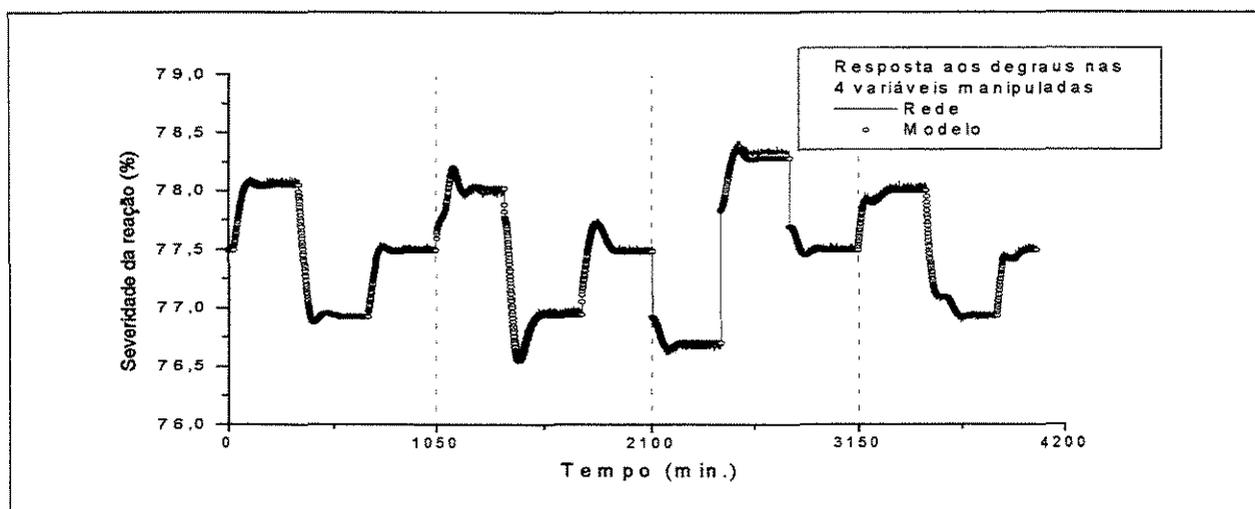
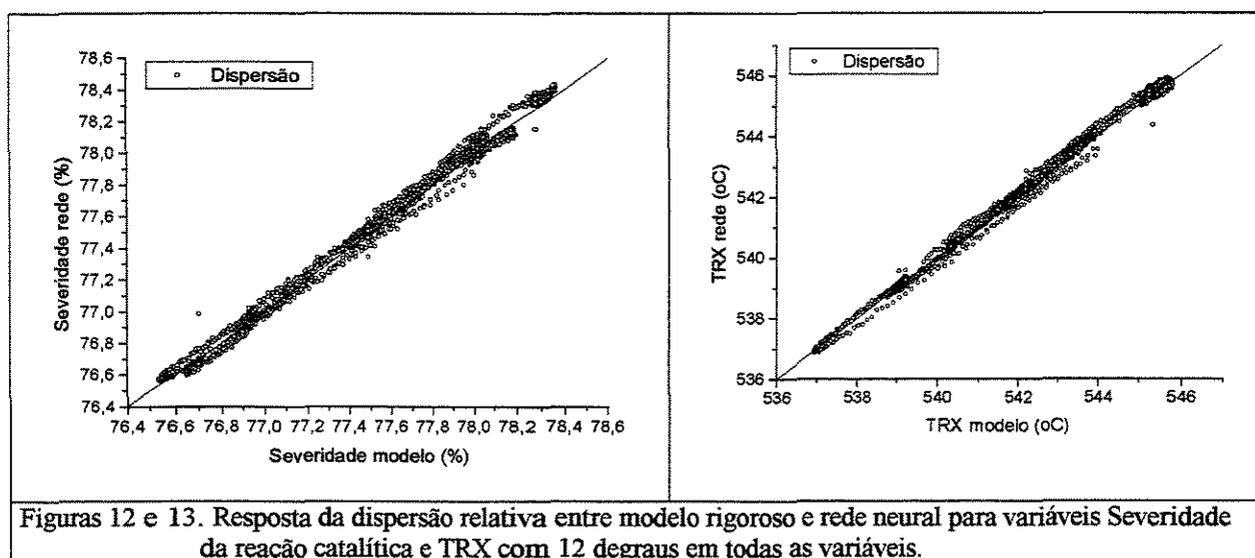


Figura 11. Resposta comparativa entre modelo rigoroso e modelo em rede neural para a variável Severidade da reação catalítica com 12 degraus em todas as variáveis manipuladas.



Figuras 12 e 13. Resposta da dispersão relativa entre modelo rigoroso e rede neural para variáveis Severidade da reação catalítica e TRX com 12 degraus em todas as variáveis.

Dos resultados obtidos, as arquiteturas escolhidas para modelar a FCC em rede neural foram  $5 \times 15 \times 4$  e  $8 \times 15 \times 4$ . Em todos os testes realizados o erro relativo das variáveis de saída foi inferior a 1%. Como resultado, foram obtidos modelos de rede neural confiáveis para a identificação de processo e eles poderão ser usados como modelo em uma estrutura de controle preditivo para o controle da FCC.

## OBSERVAÇÕES FINAIS

Este trabalho descreve um procedimento de identificação, baseado em redes neurais artificiais, de um Conversor de Craqueamento Catalítico em Leito Fluido. Um modelo fenomenológico, validado com dados reais de operação de um conversor Kellogg Orthoflow F., foi usado para gerar um conjunto de dados de variáveis operacionais. Uma rede multicamada feedforward totalmente conectada foi escolhida para a representação da

FCC. Foram adotadas duas estratégias diferentes para a arquitetura de rede: na primeira, a camada de entrada era composta por uma variável manipulada e quatro variáveis controladas, e na segunda estrutura, era composta de quatro variáveis manipuladas e quatro variáveis controladas. A vantagem principal de redes neurais em comparação ao modelo fenomenológico é o menor tempo gasto de processamento da CPU o que viabiliza sua aplicação como modelo num controle preditivo. Além disso, foi mostrado também que ambas as estruturas propostas fornecem previsões de alta qualidade das variáveis controladas. Dos resultados, as arquiteturas escolhidas para representar o modelo FCC em redes neurais foram  $5 \times 15 \times 4$  e  $8 \times 15 \times 4$ . Em todos os testes, o erro relativo das variáveis de saída foram inferiores a 1%. Como resultado, foram obtidos modelos de rede neural confiáveis para a identificação de processo e eles poderão ser usados como modelo em uma estrutura de controle preditivo para o controle do conversor FCC.

### REFERÊNCIAS BIBLIOGRÁFICAS

- 1 Narendra, K. S. & Mukhopadhyay, S., 1997, 'Adaptive Control Using Neural Networks and Approximate Models'. *IEEE Transactions on Neural Networks*, 8(3), pp. 475-485.
- 2 Narendra, K. S., 1996, 'Neural Networks for Control: Theory and Practice'. *Proceeding of the IEEE*, vol. 84(10), pp. 1385-1406.
- 3 Nikraves, M. Fareli, A. E. And Stanford, T. G., 1996, 'Model Identification of Nonlinear Time Variant Process via Artificial Neural Network'. *Computers and Chemical Engineering*, 20(11), pp. 1277-1290.
- 4 De Souza Jr, M. B. (1993) 'Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos'. Dr. Thesis, COPPE/UFRJ, Brazil.
- 5 Santos, V. M. L., Carvalho, F. R. And De Souza Jr, M. B. (2000) 'Predictive Control Based on Neural Networks: An Application to a Fluid Catalytic Cracking Industrial Unit'. *Brazilian Journal of Chemical Engineering*. 17(04-07), pp. 897.
- 6 Ansari, R. M. and Tade, M. O. (2000) 'Constrained nonlinear multivariable control of a fluid catalytic cracking process'. *Journal of Process Control* 10, pp. 539-555.
- 7 Wang, X. Z., Chen, B. H., Yang, S. H., C. McGreavy. (1999) 'Application of wavelets and neural networks to diagnostic system development, 1, feature extraction'. *Computers and Chemical Engineering* 23, pp. 899-906.
- 8 Wang, X. Z., Chen, B. H., Yang, S. H., C. McGreavy. (1999) 'Application of wavelets and neural networks to diagnostic system development, 2, an integrated framework and its application'. *Computers and Chemical Engineering* 23 pp. 945-954.
- 9 Aguilera, R., González, J, Ramirez, J. A., Barrón, M. (1999) 'Control of a fluid catalytic cracking unit based on proportional-integral reduced order observers'. *Journal of Chemical Engineering* 75 pp. 77-85.
- 10 Antoniadis, C., Christofides, P. D. (1999) 'Feedback control of nonlinear differential difference equation systems'. *Chemical Engineering Science* 54 pp. 5677-5709.
- 11 Zanin, A. C., M. Tvrzská de Gouvêa, M. and Odloak, D. (2000) 'Industrial implementation of a real-time optimization strategy for maximizing production of LPG in a FCC unit'. *Computers and Chemical Engineering* 24 pp. 525-531.
- 12 Sarma, P. and Rengaswamy, R. (2000) 'Multivariable gain-scheduled fuzzy logic control of a fluidized catalytic cracker unit'. *Computers and Chemical Engineering* 24 pp. 1083-1089.

- 13 Balchen, J.G., Lungquist D. and Strand S., (1992) 'State-space predictive control', *Chemical Engineering Sci.* 47 pp. 787-798.
- 14 Grosdidier P., Mason A., Aitolahti A., Vanhumaki V., (1993) 'FCC Unit Regenerator/reactor control', *Computers and Chemical Engineering* 17 pp. 165-179.
- 15 Ali, E.E. and Elnashaie, S., (1997) 'Nonlinear model predictive control of industrial type IV fluid catalytic cracking (FCC) units for maximum gasoline yield', *Ind. and Engng. Chem. Res.* 36 pp. 389-398.
- 16 Moro, L. F. L. (1992) 'Desenvolvimento de um controlador preditivo multivariável para um conversor industrial de Craqueamento Catalítico'. MSc. Thesis, USP/SP, Brazil.
- 17 Haykin, S. (1994) 'Neural Networks – A Comprehensive Foundation' Macmillan Publishing Co. NJ, 696p.
- 18 Simpson, P. K. (1990) 'Artificial Neural Systems: Foundations, Paradigms, Applications and Implementations'. Pergamon Press, Inc., NY, 203p.
- 19 Baughman, D. R. & Liu, Y. A. (1995) 'Neural Networks in Bioprocessing and Chemical Engineering'. Academic Press, Inc. London, 489p.
- 20 Hecht-Nielsen, R. (1989) 'Theory of the Backpropagation Neural Network', *IEEE Int. Conf. On Neural Networks*, I, pp. 593-605.

**Instituto Superior Politécnico José Antonio Echeverría  
Facultad de Ingeniería Química**

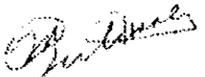
**III Taller Internacional de Análisis de Procesos**  
Ciudad de la Habana, Cuba, 24 al 26 de abril 2002

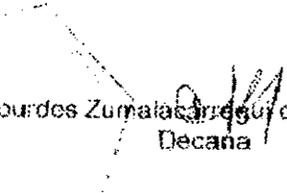
*CERTIFICADO*

A: W.G. Vieira; A.M.F. Fileti; F.R. Carvalho; J.A.F.R. Pereira

**Por su participación en el Taller con el trabajo**

*ICC UNIT: MULTIVARIABLE PREDICTIVE CONTROL WITH ANN MODELING*

  
Dña. Maritzi Gutiérrez Duque  
Presidente Comité Organizador

  
Dña. Lourdes Zumalacárregui de Cárdenas  
Decana

## FCC UNIT: MULTIVARIABLE PREDICTIVE CONTROL WITH ANN MODELING.

Vieira, W.G.<sup>1\*</sup>; Fileti, A.M.F.<sup>2</sup>; Carvalho, F.R.<sup>3</sup>; Pereira, J.A.F.R.<sup>2</sup>

- 1- CTEC/DEQ - Universidade Federal de Alagoas 57072-970 Maceió – AL – Brasil  
E-mail: [wvieira@ctec.ufal.br](mailto:wvieira@ctec.ufal.br)
- 2- DESQ/FEQ – Universidade Estadual de Campinas 13083-970 Campinas – SP – Brasil  
E-mail: [frattini@desq.feq.unicamp.br](mailto:frattini@desq.feq.unicamp.br) e [pereira@desq.feq.unicamp.br](mailto:pereira@desq.feq.unicamp.br)
- 3- CTG/DEQ - Universidade Federal de Pernambuco 50740-521 Recife – PE – Brasil  
E-mail: [florival@npd.ufpe.br](mailto:florival@npd.ufpe.br)

**ABSTRACT:** This paper propose a Multivariable Predictive Control using Artificial Neural Networks (ANN) as model of a nonlinear process. A phenomenological model that represent the FCC unit of the Henrique Lage refinery was used to obtain the ANN model. The regenerator and the reactor sections of FCC units are highly interactive with difficult dynamics, thus this units are process physically complex and prove several difficulties to operate and control. This phenomenological model was already validated with the data of the own industrial unit being therefore appropriated for this purpose. The FCC process variables controlled were: the temperature of the regenerator first stage, the temperature of the regenerator second stage, the temperature of the mixture in riser and the severity of the cracking catalytic reaction; as manipulated variables were used: regenerated catalyst flowrate at riser, air flowrate at regenerator first and second stages, the feed flowrate at riser entrance and the feed temperature at riser entrance. The purpose is maximizing production, trying to reach the optimized conversion maintaining the control variables inside of a restriction range even for the disturbances in the system. The predictive control presented good performance, when compared with the system without control in all the tested situations, taking the controlled variables to its set points.

**keywords:** multivariable predictive control, artificial neural networks, FCC.

## 1 INTRODUCTION

The FCC process represents a challenge for process industry and for control theory in function of its high complexity and operation difficulty. This unit represents the most important process in refineries of petroleum due to the higher commercial values of its products. A small benefit in this process is economically attractive. Several authors presented studies involving the FCC unit. SANTOS (2000), was presented as MSc. thesis theme a study involving the FCC unit, using ANN (Artificial Neural Network) in the process identification. This study was limited to a SISO (Single Input and Single Output) system. The control of the FCC process, using the model developed in the identification system also was proposed. The results were shown satisfactory. The same routine developed by CASTIER (1990) and De SOUZA Jr. (1993) it was used in her study. Ansari and Tade (2000) presented a strategy of nonlinear optimization with restriction applied to the FCC unit. In their study a nonlinear dynamic model of the process was used for a multivariable control system. Aguilara et al. (1999) used a project of regulatory control for stabilization of the reactor and the regenerator temperatures of FCC unit. Zanin et al. (2000) describe the implementation of a new strategy of non conventional optimization in real time applied in a FCC converter. As observed, in all these studies, a neural networks model study involving the main variables of the FCC unit assorted was not still realized.

---

\* Whom all correspondence should be addressed.

FCC converter. As observed, in all these studies, a neural networks model study involving the main variables of the FCC unit assorted was not still realized.

Any linear or nonlinear chemical process can be simulated through a neural network modeling, even when the first principles of the process are unknown. Just input/output operational data is needed (NARENDRA & MUKHOPADHYAY, 1997).

Several researches were already made based on ANN: NARENDRA (1996), summarizes the application of ANN in process control and describes the last advances in this area. The author compares ANN's mathematical bases and some successful industrial applications are mentioned.

WANG et al., (1998) presented a strategy of predictive control where a nonlinear process was modeled using ANN. Its studies were limited to the case of optimization where just one control action is involved, obviously the complexity of the problem increases when the number of variables grows. ZHAN & ISHIDA, (1997) presented a study for the predictive control model in nonlinear process with single input and single output (SISO). The basic objective in their works was select a group of futures control actions that minimized a objective function based on the technique of predictive modeling with process restrictions. They concluded that the deviation found between the model and the real system was due to absence of information in the non stable area, but even thus the model follow the real profile.

De Souza Jr. (1993) employed an ANN for process classification, where the network was used to predict the properties of a catalyst in function of the conditions of the manufacture process. The author also used the network for the identification of nonlinear reactors within a predictive control loop. In its work, he obtained satisfactory results, using the backpropagation training method with the steepest descent minimization technique. It was already used in its Dr. thesis a existent routine, based on the Castier study (CASTIER 1990) that calculates the conjugated gradient using the FLETCHER and REEVES (1964) routine. He adapted this routine in Fortran language for its conditions.

Until now none application of ANN in nonlinear multivariable control process with high interaction among its operational variables and with strong process restrictions was made.

The purpose of this work is get an alternative strategy of predictive control using ANN model, applied to a multivariable nonlinear process with restrictions. A phenomenological model that represent the FCC unit, Kellogg Orthoflow F. model was used for identification in neural networks (Vieira, et al., 2001). This model was validated with the operational data of the industrial unit by MORO (1992), in his MSc. thesis using a simulator developed by KURIHARA (1967). The fact of the model have been validated with the operational data of the industrial unit make the simulator suitable for the control purposed. In the present study, will be use the same routine developed by CASTIER (1990) and De SOUZA Jr. (1993), being necessary some fittings to adapt it to the proposed problem.

In the session 2 it is made a brief Process Description. The Methodology is presented in the session 3, the Open System in the session 3.1. the Conventional Control of FCC in the session 3.2. and the Predictive Control in the session 3.3. The Results are presented in the session 4 and the References are presented in the session 5.

## 2 PROCESS DESCRIPTION

The Fluid Catalytic Cracking (FCC) unit represented by the Kellogg Orthoflow F. model of the Henrique Lage Refinery of Petrobrás was the process chosen for this study. The converter is supposed to reduce the size of the hydrocarbon chains of the heavy petroleum fractions through catalytic reactions. This process is extremely important because derived products of petroleum of high molecular weight (that possesses little application and therefore lower commercial value) are transformed in products of higher

commercial values. The FCC unit inputs are the outputs of the following units: Vacuum Distillation (Gas-oil and Vacuum Residue) and Unit of Treatment with Propane (Heavy Oil). As products, it is obtained: Fuel Gas, Liquefied Gas of Petroleum (GLP), Cracked Naphtha, Light Cycle Oil (LCO), Decanted Oil (also denominated Fuel Oil of FCC or Cracked Fuel Oil) and Coke. These high-value products are called Cracked Naphtha, mainly used as automotive gasoline. High temperature is needed (from 500°C to 550°C) in presence of a selective catalyst. The catalyst is used in the form of a white powder with high porosity and specific area. Because of the small dimensions, it flows as if it was a fluid. Due to the operational temperature range, undesirable secondary reactions occur, such as coke formation, polymerization and dehydrogenating. As a consequence coke deposition on the surface of the catalyst occurs and therefore the catalyst activity is reduced.

The unit is composed of two sections: one of catalytic reaction, where the reactions of chain break and also coke deposition on the catalyst take place; and the other, where burn of the coke occurs, regenerating the catalyst (see Figure 1). Then the catalyst is forced to pass from the reaction section to the regeneration section, and finally coming back for the reaction section (see Figure 2). The regeneration reaction is carried out through air injection and burning in the regenerator.

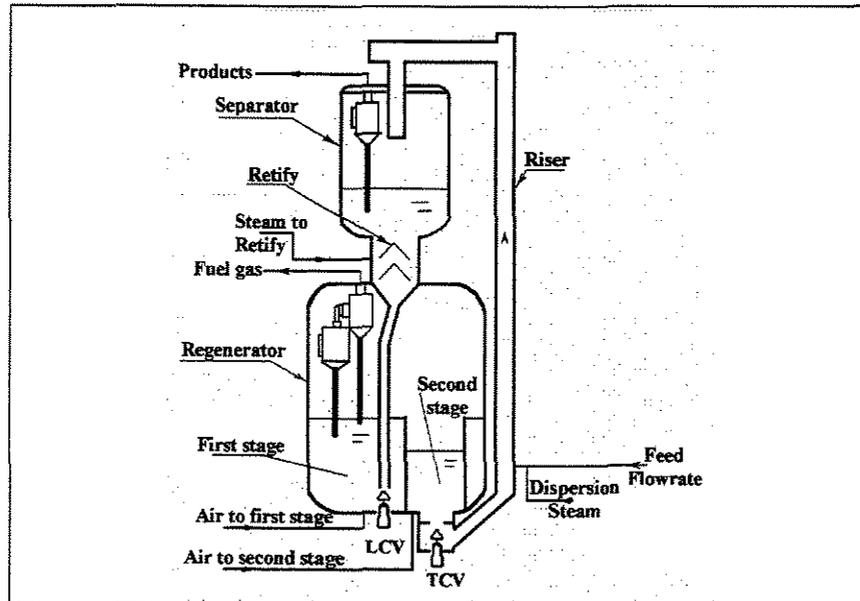


Figure 1 Schematic draw of the FCC of Henrique Lage Refinery.

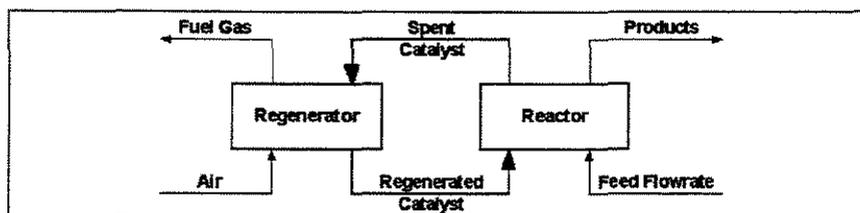


Figure 2 Schematic draw of the catalyst circulation.

Due to the extremely severe conditions of operation, rigorous control of some operational variable (controlled) is needed. Several variables can be taken as controlled in the industry. In this study the following variables will be used: temperature of cracking mixture in riser (TRX), temperature of dense phase at regenerator first and second stages (TRG1 and TRG2) and conversion of the reactor (Severity of the cracking reaction). The following variables will be manipulated: total feed flowrate to riser (RTF), regenerated

catalyst valve opening (CTCV), air flowrate to regenerator (RAI) and feed temperature at riser entrance (TFP). Besides these variables, the process requires the maintenance of other variables between their restriction limits, such as: differential pressure on the reactor level control valve, temperature of the regenerator first stage dilute phase and temperature of the regenerator global dilute phase.

### 3 METHODOLOGY

The predictive control, has this denomination due to the form as the calculation of the control law is made, that is, in the current instant, called "k" instant is made the forecast of the process for future instants, "k+1", "k+2",..., "k+Np", where Np is denominated prediction horizon. By a model, previously defined, forecasts of the answers of the process simulating alterations in the manipulated variables for Nc future instants are made; Nc represents the control horizon. The manipulated variables that supply only answers with certain characteristics are selected. Then, the first prediction action is implemented in the control. After implementation, the time is updated for "k+1" and the calculation is repeated. Usually, the approach among the predicted response and the wish response is adopted for choice of the control action. This comparison is made by means of minimization of algebraic equations. These equations are functions of the predicted control variable -  $\hat{y}$ , the manipulated variable -  $u$  and a set point -  $sp$ . Then, the future error is minimized, and if the chosen model represents exactly the process and if disturbances don't happen, the process will follow the reference trajectory faithfully (FILETI, 1998).

The algebraic equation is defined by,

$$j = \sum_{i=1}^{N_p} \alpha_q (\hat{y}_q(k+i) - sp_q(k+i))^2 + \sum_{i=0}^{N_c} \lambda_r (u'_r(k) - u'_r(k-1))^2$$

subject the following restrictions:

$$\begin{aligned} y_{min} &\leq \hat{y}(k+i) \leq y_{max}, i = 1, \dots, N_p \\ u_{min} &\leq u(k+i-1) \leq u_{max}, i = 1, \dots, N_p \\ [u(k+i) - u(k+i-1)] &\leq \Delta u_{max}, i = 1, \dots, N_c \end{aligned} \quad (3.1)$$

where  $\lambda$  are the weights used to avoid excessive variations of the manipulated variable, and  $\alpha$  are the tune weights used in the controlled variables, the indexes  $q$  and  $r$  represent the controlled variables and manipulated variables, respectively.

The reference trajectory for the control strategy is given by:

$$\begin{aligned} y_{sp}(k) &= y(k) \\ y_{sp}^{(k+i)} &= \beta y_{sp}^{k+i-1} + (1-\beta)sp \end{aligned} \quad (3.2)$$

where  $\beta$  assumes one of the following values: 0,85; 0,90; 0,95 and 0,97, depends on the control tune. Each prediction of the neural network was corrected by:

$$c(k) = y(k) - \hat{y}(k | k-1)$$

The corrected prediction is:

$$\hat{y}_c(k+1 | k) = \hat{y}(k+1 | k) + c(k) \quad (3.3)$$

where  $y(k)$  it is the real output of the process in time "k",  $\hat{y}(k|k-1)$  the prediction of variable  $y$  for the instant "k" obtained by the neural network in time "k-1" and  $\hat{y}_c(k|k+1)$  is the corrected predicted variable.

### 3.1 Open System

The same disturbances proposed for the control test were imposed to the model in open loop, using the phenomenological model routine. Then is hopes to get to accomplish a comparison among the tests with and without control action. The results of the behavior of the model without control action and the results obtained with the control action were shown in graphs forms (Figures 5 to 7).

### 3.2 FCC usual control

Initially, a description of the FCC conventional control is presented. The Figure 3 is useful for its understanding.

The feed usually coming from the tank system and it has an independent control. It is heated up in a feed heating. The temperature of this stream is controlled by a feed fuel control. The temperature of "Riser" output is controlled by the regenerated catalyst valve. The catalyst level in the separator vessel is controlled by the spent catalyst valve. The temperatures of the dense and diluted beds phases are controlled by air flowrate to regenerator. The reactor and regenerator pressure differential is controlled by combustion gases valve.

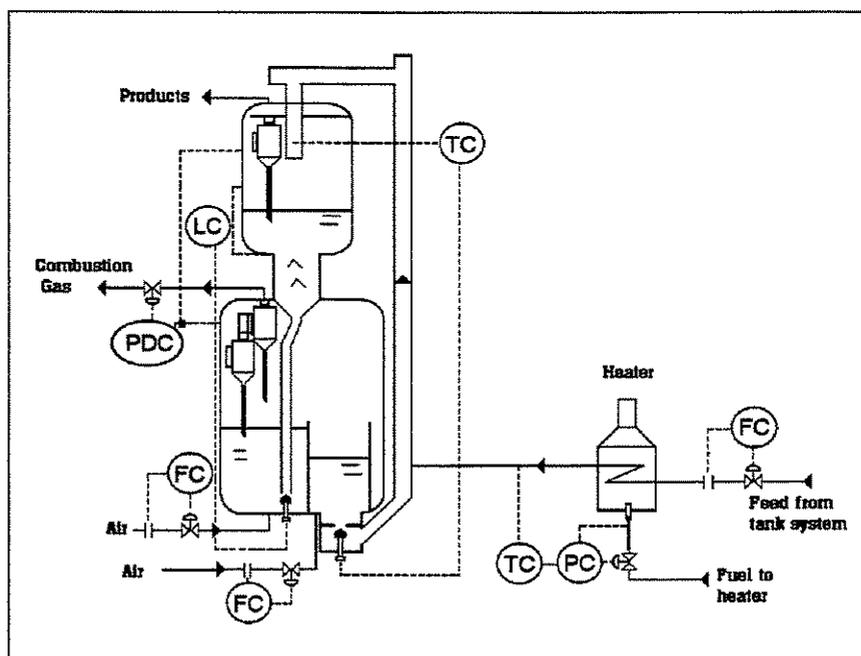


Figure 3 Schematic draw of FCC conventional control

### 3.3 Predictive Control

The computational control routine was developed using Fortran language, being inserted in phenomenological model routine. The minimization process (minimization of objective function) was accomplished using the NCONF routine, of the IMSL Fortran Library. This routine implements the Successive Quadratic Programming - SQP and the Finite Difference Gradient method, but the sources programs don't allow access. The manipulated and controlled variables were normalized in the same shape of the

normalization method used in the process identification, when the neural network was developed (Vieira, et al., 2001).

The model in neural networks was trained considering the action of degrees in each variable manipulated individually, but the DNC (Dynamic Networks Control), foresees the performance in the whole manipulated variables simultaneously. The diagram of the Figure 4 show an outline of a predictive control using ANN.

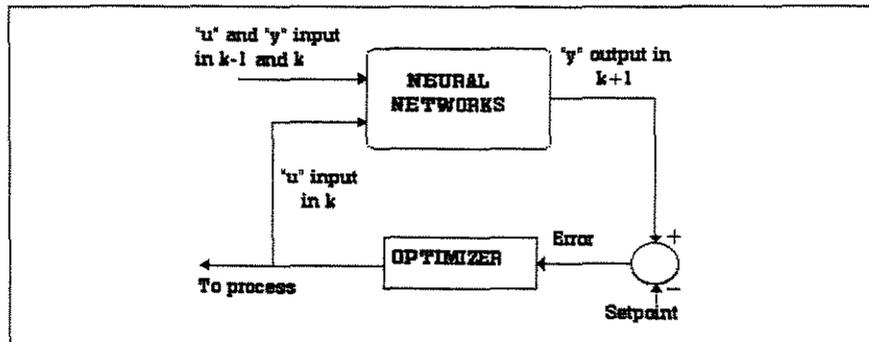


Figure 4 Schematic draw of DNC using ANN.

The Figure 5 show a sketch of the proposed control system, already coupled to the conventional system.

The control action can be obtained with optimization strategies of the plant. These strategies are obtained by external actions, where it can be determined which variable will be manipulated changing its restriction limits. Two strategies of optimization have interest in industrial plant: the first one is the maximization or the minimization production strategy, by RTF variable; the second strategy is, the change the objective of the unit to produce GLP instead of Naphtha, by TRX variable.

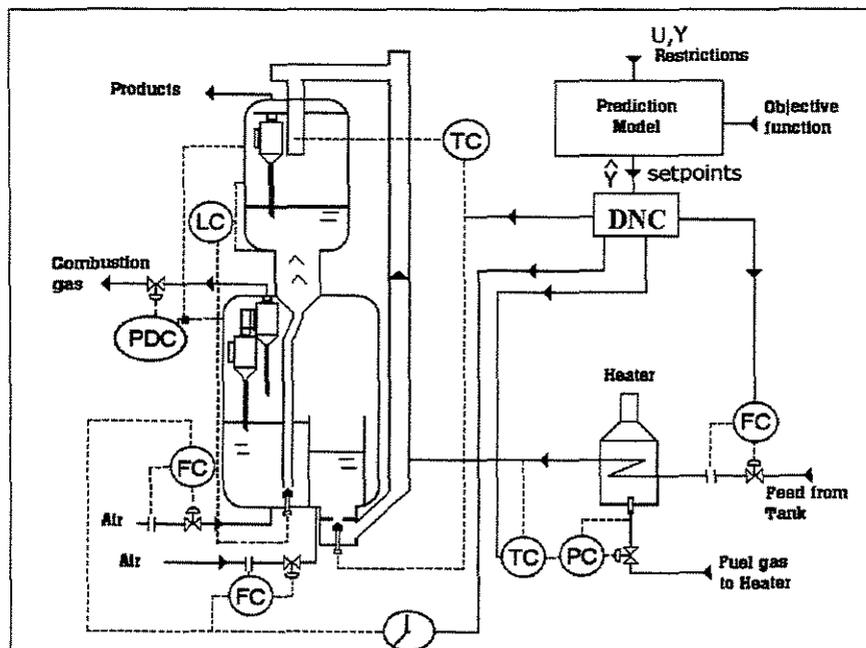


Figure 5 DNC proposed coupled to the conventional system

By mathematical simulation through the phenomenological model (ODLOAK, 1997) were obtained the data of the controlled and manipulated variables that compose the input to the DNC control. With this data the optimization routine is called and the predictions of

the actions in the manipulated variables are done. The ANN is used to get the response of those actions in the controlled variables in every prediction horizon ( $N_p$ ). The results of those predictions supply the control actions in every control horizon ( $N_c$ ). After the actions that minimize the differences among the reference trajectories in the control horizon be selected, the first control action is sent to the phenomenological model program to print the results, then the control program is await for new sampling instant, and the cycle begin again.

The DNC test were simulate 800 minutes, with control action beginning from the 100th minute, a disturbance beginning from the 400th minutes. The program simulator (phenomenological model) begins out of the steady state, denominated of initial condition of operation; therefore, after beginning of the control action, time 100 minutes, the controller begins an action of taking the variables controlled for its set points. This justifies the change observed in all the graphs in the interval among 100 minutes and 400 minutes.

A noise by 1,5% of intensity was inserted in the signs of the controlled variables before the called of the optimization program, in the attempt of approaching the simulator to the real conditions of operation; nevertheless, the neural network was capable to predict the behavior of the model for all variables involved in the process.

#### 4.RESULTS

For test simulation was intend to apply a disturb in degree form in temperature of the air to the regenerator, TAI variable, altering its value in +8%. The sampling of 4,0 in 4,0 minutes was considered, with  $N_p$  equal to 10, and  $N_c$  equal to 1. The weight factors  $\lambda_i$  were:  $1,0e-3$  for TFP,  $3,0e-4$  for RAI,  $6,0e-4$  for RTF, and  $5,0e-2$  for CTCV; and the weight factors  $\alpha_i$ , that define the relevance of each controlled variable, were:  $1,0e-3$  for TRG1,  $1,0e-5$  for TRG2,  $1,0e-4$  for SEV and  $5,0e-3$  for TRX. The filter used for the reference trajectory was  $9,0e-1$  for all variables, and the optimization strategy considered for the test was to fix the feed flowrate to riser, variable RTF.

The graphs of the Figures 6 to 13 show the responses to the disturbance of 8% in variable TAI; these responses are presented in comparative form among the results with control action (full line) and without control action or open system (dash line).

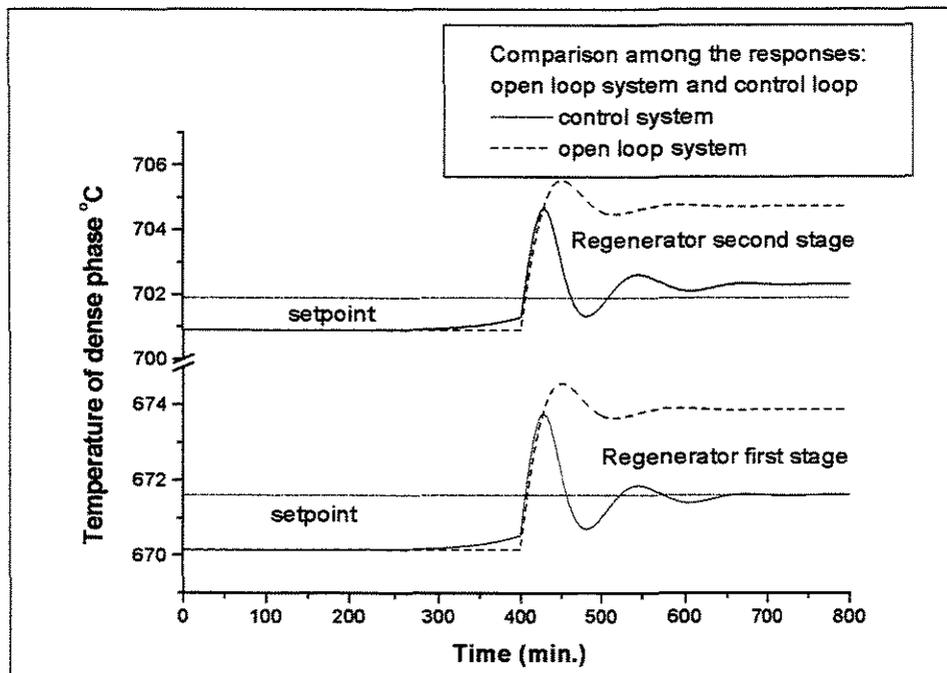


Figure 6 Response in Regenerator after disturbance in TAI variable. Comparison among open loop (dash line) and control loop (full line).

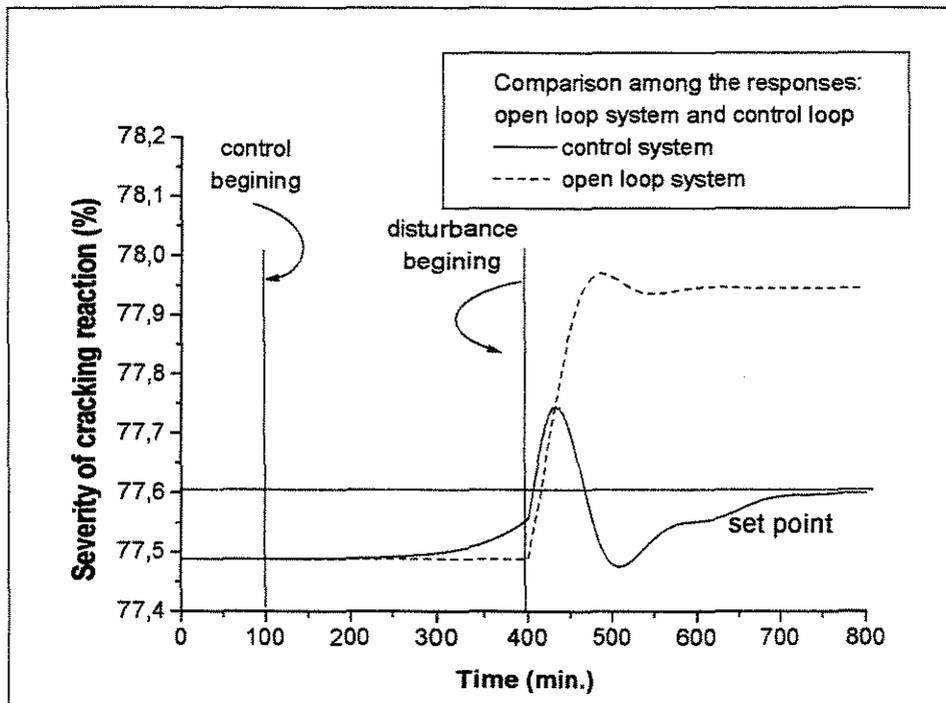


Figure 7 Response in Severity of catalytic reaction after disturbance in TAI variable. Comparison among open loop (dash line) and control loop (full line).

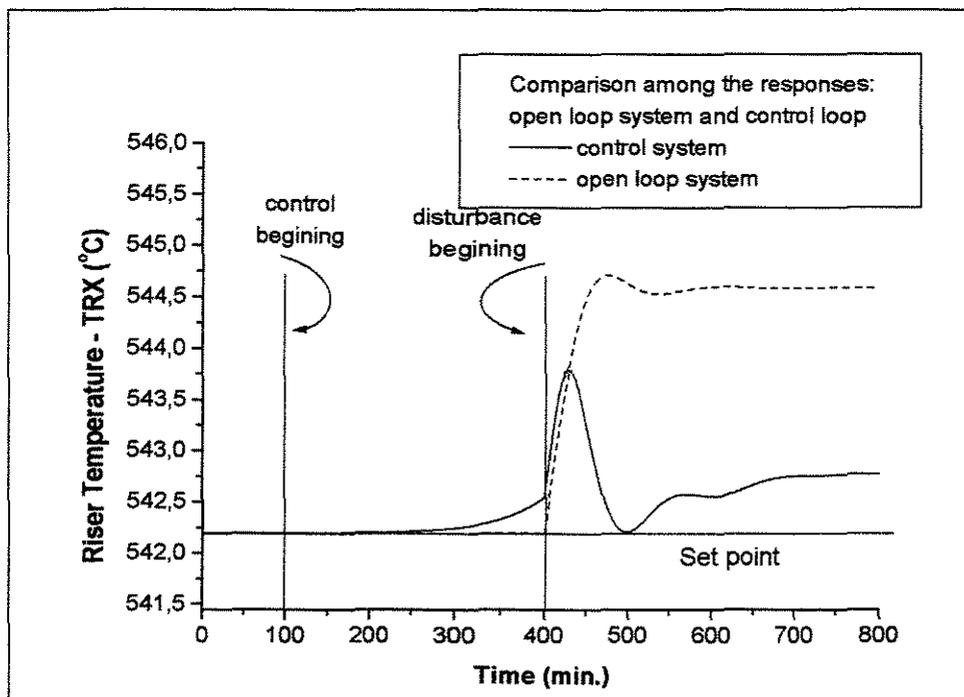


Figure 8 Response in Riser output after disturbance in TAI variable. Comparison among open loop (dash line) and control loop (full line).

The elevation of TAI results in an immediate elevation of TRG1 and TGR2, that results too in the elevation of the temperature of the regenerated catalyst that also elevated TRX and SEV. These increases were corrected simultaneously by the control

action that reduced the air flowrate to regenerator, reduced too the catalyst flowrate to riser, by reducing the CTCV variable and the TFP, gradually. The feed flowrate to riser (see Figure 11) was maintained fixed as it was defined.

The TRG2 and TRX variables stay close to its set points; in the TRG2 variable that is justified due to the fixed rate among the air to first and to second stage; in the TRX variable that is justified by an interdependence observed between this variable and the severity of the catalytic reaction; but despite this, these results were considered satisfactory.

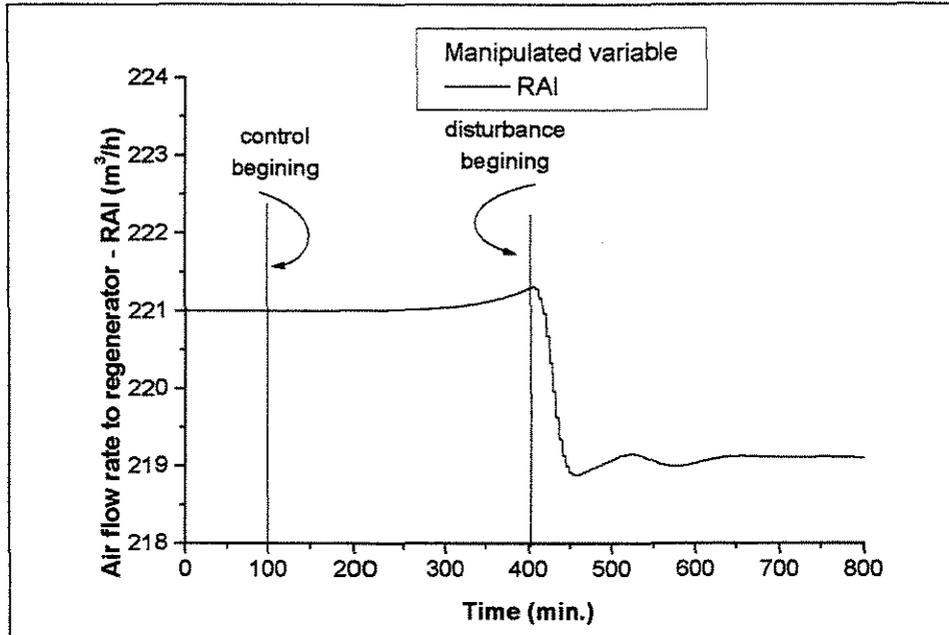


Figure 9 Optimizer action in manipulated variable – RAI, after disturbance in TAI variable.

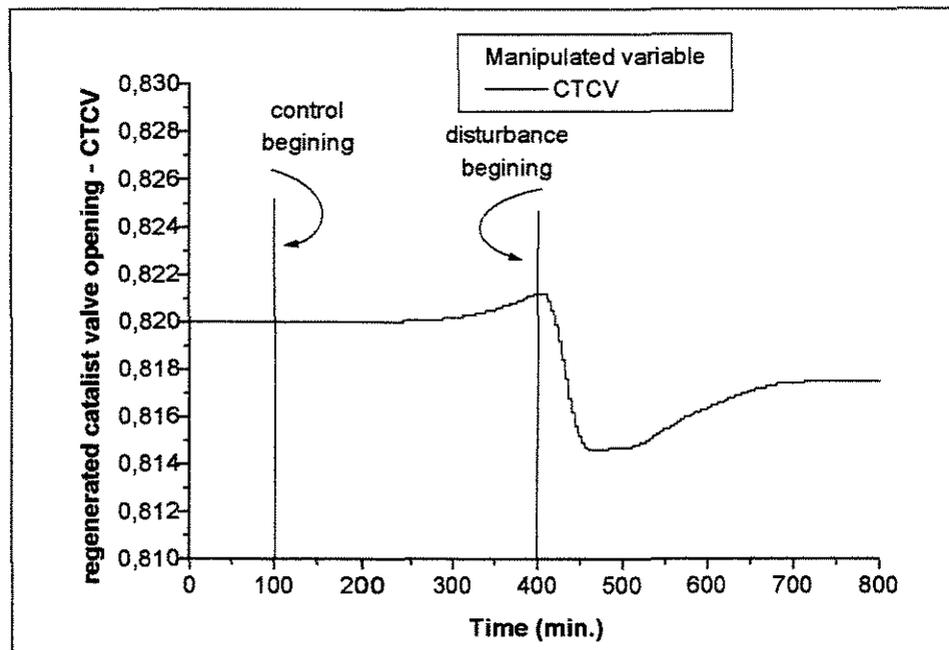


Figure 10 Optimizer action in manipulated variable – CTCV, after disturbance in TAI variable.

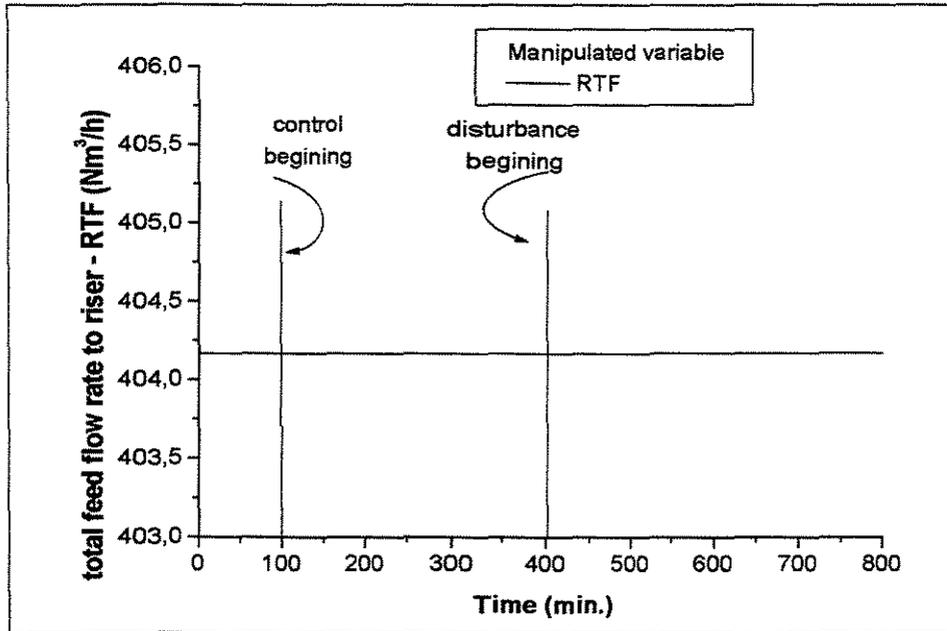


Figure 11 Optimizer action in manipulated variable – RTF (fixing this variable as wished) after disturbance in TAI variable.

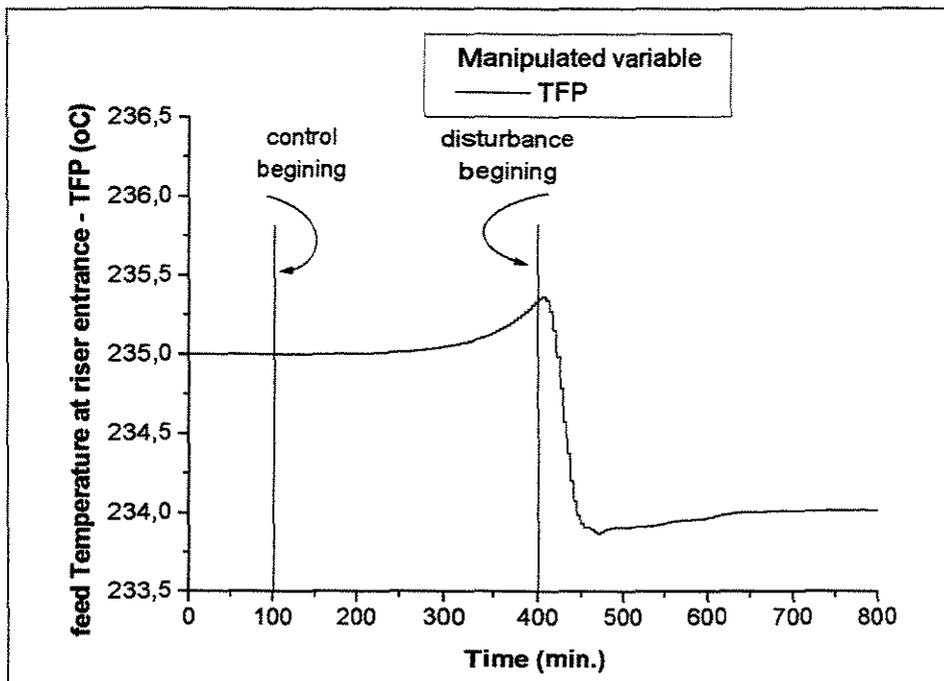


Figure 12 Optimizer action in manipulated variable – TFP, after disturbance in TAI variable.

The test was done too with change in operational strategy producing GLP despite of Nafta and the results were too satisfactory.

The control proposed DNC presented excellent results in all the tested situations, in spite of considering  $N_c$  equal to 1. Whether the control taking the variables to their set point or in the optimization where the control associates a search of certain operational condition. It is believed that elevating the control horizon for  $N_c > 1$ , the results will be better, reducing the time of the control response; this was not still made due to the extreme difficulty of tune the multivariable control.

## 5 REFERENCE

- AGUILARA, R., GONZÁLEZ, J., RAMIREZ, J. A., BARRÓN, M. Control of fluid catalytic cracking unit based on proportional-integral reduced order observers. *J. Chem. Engng.* v. 75, p. 77-85, 1999.
- ANSARI, R. M. & TADÉ, M. O. Constrained nonlinear multivariable control of a fluid catalytic cracking process. *J of Proc Cont* v.10, p. 539-555, 2000.
- DE SOUZA JR, M. B. Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos. Rio de Janeiro: COPPE/UFRJ, 1993. 124 p. Tese (doutorado)
- FILETI, A. M. F. Controle avançado de Processos: Adaptativo, Preditivo e Fuzzy. Modelagem Matemática via Redes Neurais. Aplicações em Processos Químicos. (curso ministrado na Escola Politécnica da Universidade Federal da Bahia).
- KURIHARA H. Optimal Control of Fluid Catalytic Cracking Processes. MIT: Science Dr. Thesis, 1967. Tese (doutorado)
- MORO, L. F. L. Desenvolvimento de um Controlador Preditivo Multivariável para um Conversor Industrial de Craqueamento Catalítico. São Paulo: USP, 1992, 77 p. Dissertação (Mestrado)
- NARENDRA, K. S. Neural Networks for Control: Theory and Practice. *Proc. of IEEE*, Oct 1996. v. 84, n. 10.
- NARENDRA, K. S. and MUKHOPADHYAY, S. Adaptive Control Using Neural Networks and Approximate Models. *IEEE Trans. on N. Net.*, v. 8, n. 3, May 1997.
- SANTOS, V. M. L. Identificação e Controle Preditivo Baseado em Redes Neurais de Processos de Craqueamento Catalítico em Leito Fluidizado. Recife, PE: DEQ/UFPE, 101p. 2000b. dissertação (mestrado)
- VIEIRA, W.G., FILETI, A.M.F., CARVALHO, F.R., PEREIRA, J.A.F.R. FCC: Process Identification Through Artificial Neural Networks. *Proceedings of 6<sup>TH</sup> World Congress of Chem Engng. Australia.* 2001.
- WANG, H., OH, Y. and YOON, E. S. Strategies for Modeling and Control of Nonlinear Chemical Processes using Neural Networks. *Comp. Chem. Engng.* v. 22, Suppl., p. S832-S862, 1998.
- ZHAN, J. & ISHIDA, M. The Multi-step Predictive Control of Nonlinear SISO Processes with a Neural Model Predictive Control (NMPC) Method. *Computers chem. Engng.*, v. 21, n. 2, p. 201-210, 1997.

# COBEQ

XIV CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA

2002

## Programação

Dia/hora	Código	Título
27/8-15H:50 <i>16h:10</i>	489	SOBRE A MODELAGEM MATEMÁTICA E EFEITOS DE GEOMETRIA NA SIMULAÇÃO BIFÁSICA DE UM RISEP
27/8-15H:50	702	FCC: UMA ALTERNATIVA DE CONTROLE PREDITIVO MULTIVARIÁVEL POR REDE DINÂMICA
28/8-9H:50	488	CONTROLE DE QUALIDADE MELHORADO DE RESINAS DE POLIPROPILENO BIMODAL
28/8-9H:50	859	MODELAGEM MATEMÁTICA DA DISTRIBUIÇÃO DE TAMANHO DAS PARTÍCULAS DE POLIESTIRENO PRODUZIDAS POR POLIMERIZAÇÃO EM SEMI-SUSPENSÃO
28/8-10H:10	704	UM NOVO SIMULADOR DE SÉRIES TEMPORAIS PARA REDES DE DUTOS COM FLUIDOS INCOMPRESSÍVEIS
28/8-10H:10	955	SIMULAÇÃO DINÂMICA DE REDES DE DUTOS OPERANDO COM FLUIDOS COMPRESSÍVEIS DENSOS
28/8-10H:30	505	COMPARAÇÃO DE DIFERENTES MÉTODOS DE IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS NÃO LINEARES. 1ª PARTE: REVISÃO DA TEORIA
28/8-10H:50	504	COMPARAÇÃO DE DIFERENTES MÉTODOS DE IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS NÃO LINEARES. 2ª PARTE: RESULTADOS NUMÉRICOS
28/8-11H:10	536	ESTUDO DA DINÂMICA DE UM REATOR DE POLIMERIZAÇÃO COM RESFRIAMENTO POR EVAPORAÇÃO
28/8-11H:30	572	SIMULAÇÃO ESTACIONÁRIA DA POLIMERIZAÇÃO EM LAMA E EM MASSA DE PROPILENO
28/8-12H:10	707	SIMULAÇÃO ESTACIONÁRIA DE REDES DE DUTOS UTILIZANDO UM MODELO DE ESCOAMENTO SIMPLIFICADO
28/8-14H:30	578	ALGORITMO PARA PREVISÃO DE PLANOS EXPERIMENTAIS SEQUENCIAIS



XIV CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA

# CERTIFICADO

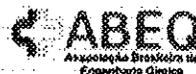
Certificamos que WILLIAN GONÇALVES VIEIRA participou do XIV Congresso Brasileiro de Engenharia Química, realizado de 25 a 28 de agosto de 2002, em Natal - RN, na condição de PARTICIPANTE.

Natal (RN), 28 de agosto de 2002

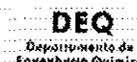
Prof.<sup>a</sup> Márcia Maria Lima Duarte  
Presidente do COBEQ 2002

Prof. Garette Ribeiro de Macedo  
Coordenadora do comitê técnico-científico

Realização:



Organização:



## FCC: UMA ALTERNATIVA DE CONTROLE PREDITIVO MULTIVARIÁVEL POR REDE DINÂMICA.

Vieira, W.G.<sup>1</sup>; Fileti, A.M.F.<sup>2\*</sup>; Carvalho, F.R.<sup>3</sup>; Pereira, J.A.F.R.<sup>2</sup>

- 1- CTEC/DEQ - Universidade Federal de Alagoas 57072-970 Maceió. AL Brasil E-mail: [wgv@ctec.ufal.br](mailto:wgv@ctec.ufal.br)
- 2- DESQ/FEQ - Universidade Estadual de Campinas 13083-970 Campinas. SP Brasil E-mail: [frattini@desq.feq.unicamp.br](mailto:frattini@desq.feq.unicamp.br) e [pereira@desq.feq.unicamp.br](mailto:pereira@desq.feq.unicamp.br)
- 3- CTG/DEQ - Universidade Federal de Pernambuco 50740-521 Recife - PE - Brasil E-mail: [florival@npd.ufpe.br](mailto:florival@npd.ufpe.br)

**RESUMO:** O objetivo do presente estudo é propor um Controlador Preditivo Multivariável utilizando Redes Neurais Artificiais como modelo de predição para controlar um processo não linear. Um modelo fenomenológico representando a unidade de Craqueamento Catalítico da refinaria Henrique Lage foi utilizado para gerar o modelo em redes neurais. Este modelo fenomenológico já foi validado com os dados da própria unidade industrial sendo portanto adequado para este propósito. As variáveis controladas do processo são: temperaturas do regenerador 1<sup>o</sup> e 2<sup>o</sup> estágios, temperatura do riser e severidade da reação; como manipuladas são utilizadas: vazão de catalisador, vazão do ar e vazão e temperatura da carga. É proposto maximizar a produção, procurando atingir a conversão otimizada mantendo as variáveis do processo dentro de uma faixa de controlabilidade frente às perturbações no sistema. O controlador desenvolvido apresentou bom desempenho, comparado com o sistema aberto, em todas as situações testadas levando as variáveis controladas para o *set point*.

**PALAVRAS-CHAVE:** controle preditivo multivariável, redes neurais artificiais e FCC.

**ABSTRACT:** This paper propose a Multivariable Predictive Control using Artificial Neural Networks (ANN) as model of a non-linear process. A phenomenological model that represent the FCC unit of the Henrique Lage refinery was used to obtain the ANN model. This model was already validated with the data of the own industrial unit being therefore appropriated for this purpose. The process variables controlled were: temperatures of the regenerator first and second stage, the temperature of the mixture in riser and the severity of the cracking reaction; as manipulated variables were used: catalyst flow rate at riser, air flow rate at regenerator and feed flow rate and temperature at riser entrance. The purpose is maximizing production, trying to reach the optimization of conversion maintaining the control variables inside of a restriction range even for the disturbances in the system. The predictive control presented good performance, when compared with open system in all the tested situations, taking the controlled variables for the set point.

### 1.INTRODUÇÃO

A introdução de computadores digitais de baixo custo e alta velocidade de processamento tem encorajado o uso de métodos matemáticos complexos e mais

precisos em engenharia de sistemas. Este avanço tecnológico possibilitou o uso de redes neurais artificiais (RNA) como ferramenta para controle de sistemas químicos. As RNA permitem que se simule um processo químico qualquer, sendo ele

---

\* Autor para o qual toda a correspondência deve ser enviada.

linear ou não linear, conhecendo-se um histórico operacional do processo ou apenas conhecendo-se os dados de entrada e as respostas correspondentes, mesmo que não se tenha certeza do mecanismo do processo (NARENDRA & MUKHOPADHYAY, 1997).

Diversos estudos relacionados a RNA têm sido encontrados na literatura. NARENDRA (1996), apresenta em um resumo a aplicação de RNA em controle de processo, incluindo algumas aplicações industriais de sucesso. WANG et ali., (1998) apresentou uma estratégia de controle preditivo onde um processo não linear é modelado usando RNA. Seus estudos se limitaram ao caso de otimização onde apenas uma ação de controle é envolvida, obviamente a complexidade do problema aumenta quando o número de variáveis cresce. ZHAN & ISHIDA, (1997) apresentaram um estudo para o controle preditivo com modelo em um processo não linear com uma única entrada e única saída (*SISO - Single Input and Single Output*). A proposta apresentada foi utilizar controle preditivo utilizando RNA para simulação do modelo. O objetivo básico foi selecionar um conjunto de ações de controle futuro que minimizasse uma função objetivo baseado na técnica de modelagem preditiva, sujeito a restrições de processo. Eles concluíram que o desvio encontrado entre o modelo e o sistema real foi devido a ausência de informações na região não estável, mas que o perfil do modelo acompanhou o perfil real. Porém, seu estudo se limitou a um sistema SISO. De SOUSA Jr., (1993) empregou uma RNA para identificação de um processo catalítico. O autor também usa a rede para a identificação de reatores não lineares com controle preditivo. Em seu trabalho, ele obteve resultados satisfatórios, usando o método de treinamento “*backpropagation*”, com a técnica “*steep descent*” como rotina de minimização. Foi usado na sua tese de doutorado uma rotina

já pronta, baseada no estudo de CASTIER (1990), que calcula o gradiente conjugado de FLETCHER e REEVES (1964). Ele adaptou esta rotina em linguagem Fortran para suas condições.

O processo da FCC em função de sua elevada complexidade e dificuldade de operação e controle representa um desafio onde benefícios significativos para indústria de processo e para teoria de controle poderiam ser alcançados. Esta unidade, em virtude do elevado valor agregado de seus produtos representa o processo mais importante em refinarias de petróleo. Um pequeno benefício neste processo é economicamente atraente. Diversos autores apresentaram estudos envolvendo a unidade de FCC. SANTOS (2000), apresentou como tema de mestrado um estudo utilizando RNA na identificação desta unidade. Este estudo se limitou a sistema SISO. Foi proposto também o controle do processo da FCC, utilizando o modelo desenvolvido na identificação. Os resultados se mostraram satisfatórios. A mesma rotina desenvolvida por CASTIER (1990) e De SOUZA Jr. (1993) foi utilizada em seu estudo. Ansari and Tade (2000) apresentaram uma estratégia de otimização não linear com restrição aplicada à unidade de FCC. Neste estudo um modelo dinâmico não linear do processo foi usado para um sistema de controle multivariável. AGUILARA et al. (1999) utilizaram um projeto de controle regulatório para estabilização das temperaturas do reator e do regenerador de uma unidade de FCC. Zanin et al. (2000) descrevem a implementação de uma nova estratégia de otimização não convencional em tempo real aplicada em um conversor FCC. Conforme observado em todos estes estudos foram utilizados modelos fenomenológicos, e um modelo em redes neurais envolvendo as principais variáveis da unidade FCC juntas ainda não tinha sido realizado.

A meta a ser alcançada neste trabalho foi obter uma estratégia alternativa de controle preditivo usando as RNA como modelo do controlador, aplicadas a um processo multivariável não linear e com restrições. Para representar o processo multivariável, um modelo fenomenológico que simula a unidade de Craqueamento Catalítico, modelo *Kellog Orthoflow F.*, foi utilizado para identificação em redes neurais (VIEIRA, et al., 2001). MORO (1992), em sua dissertação de mestrado utilizando um simulador desenvolvido por KURIHARA (1967), validou este modelo fenomenológico com os dados da unidade industrial, criando um controlador DMC e acoplando-o ao simulador. O fato do modelo já ter sido validado com os dados da unidade industrial tornou este simulador bastante adequado para o propósito aqui apresentado. Com o controlador é proposto otimizar a produção de Nafta, ou alternativamente GLP, de forma a atingir a conversão otimizada frente às perturbações no sistema.

No presente estudo, é previsto utilizar a mesma rotina desenvolvida por CASTIER (1990) e De SOUZA Jr. (1993), sendo necessário alguns ajustes para adaptá-la ao problema proposto. Na sessão 2 é feita uma breve Descrição do Processo. A Metodologia é apresentada na sessão 3, o cálculo do Sistema Aberto na sessão 3.1. o Controle Convencional da FCC na sessão 3.2. e o Controlador Preditivo na sessão 3.3. Os Resultados são apresentados na sessão 4 e as Referências Bibliográficas são apresentadas na sessão 5.

## 2. DESCRIÇÃO DO PROCESSO

A unidade de Craqueamento Catalítico apresenta como objetivo o de reduzir o tamanho das redes hidrocarbônicas das frações mais pesadas do petróleo por meio de reações catalíticas. Este processo é extremamente útil pois

transforma produtos derivados de petróleo de alto peso molecular e que possuem baixo valor agregado em produtos de maior valor comercial. Esta unidade gera os seguintes produtos: Gás Combustível; Gás Liquefeito de Petróleo; Nafta Craqueada; Óleo Leve de Reciclo; Óleo Decantado e Coque. Desses produtos, o que apresenta maior valor agregado é a Nafta Craqueada, utilizada como gasolina automotiva, sendo portanto esta a principal meta dessa unidade. Devido às condições de temperatura do reator, ocorre deposição de coque sobre a superfície do catalisador, reduzindo sua atividade. A unidade é composta de duas seções, uma de reação catalítica, e a outra onde ocorrem as reações de queima do coque com injeção de ar, regenerando o catalisador (Figura 1).

O controle rigoroso de algumas variáveis operacionais (controladas), é feito por meio de alterações em outras variáveis do processo (manipuladas). Diversas variáveis podem ser usadas como controle na indústria, porém, algumas delas apresentam maior facilidade de medição ou então influenciam diretamente as demais variáveis; então, estrategicamente, neste estudo foram escolhidas como variáveis controladas: a temperatura do *riser*, TRX; as temperaturas das fases densas do primeiro e segundo estágios de regeneração, TRG1 e TRG2; e a severidade da reação catalítica, SEV. As seguintes variáveis foram consideradas como manipuladas: vazão da carga, RTF, vazão de catalisador regenerado, CTCV, vazão de ar para o regenerador, RAI e temperatura da carga, TFP.

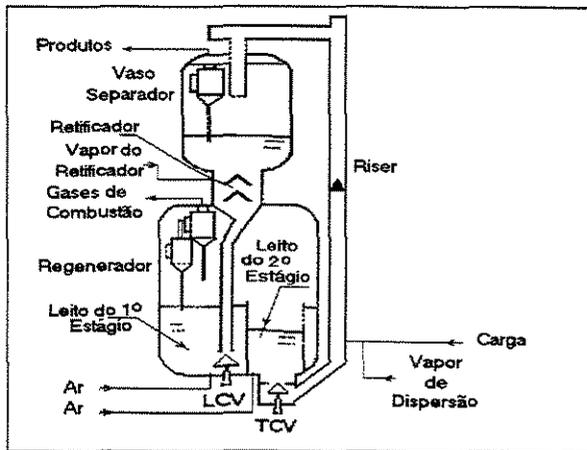


Figura 1 Esquema da FCC da Refinaria Enrique Lage.

### 3. METODOLOGIA

O controle preditivo, é assim denominado devido à forma como é feito o cálculo da lei de controle, ou seja, no instante atual, chamado instante “ $k$ ” é feita a previsão do processo para instantes futuros, “ $k+1$ ”, “ $k+2$ ”, ..., “ $k+N_p$ ”, onde  $N_p$  é denominado horizonte de predição. A partir de um modelo, previamente definido, são feitas previsões das respostas do processo simulando alterações nas variáveis manipuladas para  $N_c$  instantes futuros, onde  $N_c$  representa o horizonte de controle. São feitas então seleções destas variáveis de forma a escolher aquelas que fornecem somente respostas com determinadas características. Então, a primeira predição é implementada na ação do controlador. Após implementação, o tempo é atualizado para “ $k+1$ ” e todo o cálculo é repetido. Normalmente, adota-se um critério de comparação entre a resposta predita e a resposta desejada para escolha da ação do controlador. Esta comparação é feita por meio de minimização de equações algébricas que geralmente são funções da variável controlada predita -  $\hat{y}$ , da variável manipulada -  $u$  e de uma trajetória de referência -  $sp$  (set point). Desta forma, o erro futuro é minimizado, e se o modelo escolhido representar bem o processo e se não ocorrerem perturbações, o processo

seguirá fielmente a trajetória de referência (FILETI, 1998).

A equação algébrica é definida como,

$$j = \sum_{i=1}^{N_p} \alpha_q (\hat{y}_q(k+1) - sp_q(k+1))^2 + \sum_{i=0}^{N_c} \lambda_r (u'_r(k) - u'_r(k-1))^2$$

sujeito as seguintes restrições:

$$\begin{aligned} y_{min} &\leq \hat{y}(k+i) \leq y_{max}, i = 1, \dots, N_p \\ u_{min} &\leq u(k+i-1) \leq u_{max}, i = 1, \dots, N_p \\ [u(k+i) - u(k+i-1)] &\leq \Delta u_{max}, i = 1, \dots, N_c \end{aligned} \quad (3.1)$$

onde  $\lambda$  são os pesos utilizados para penalizar variações excessivas da variável manipulada, e  $\alpha$  são os pesos de igual importância utilizados nas variáveis controladas, os índices  $q$  e  $r$  representam as variáveis controladas e manipuladas. A trajetória de referência para a estratégia de controle é dada pelo modelo:

$$\begin{aligned} y_{sp}(k) &= y(k) \\ y_{sp}^{(k+i)} &= \beta y_{sp}^{k+i-1} + (1-\beta)sp \end{aligned} \quad (3.2)$$

onde  $\beta$  assume um dos seguintes valores: 0,85; 0,90; 0,95 e 0,97, dependendo do ajuste do controlador. Cada predição de um passo adiante da rede neural foi corrigida usando uma variável de correção fornecida por:

$$c(k) = y(k) - \hat{y}(k | k-1)$$

A predição corrigida então fica:

$$\hat{y}_c(k+1 | k) = \hat{y}(k+1 | k) + c(k) \quad (3.3)$$

onde  $y(k)$  é a saída real do processo no tempo de amostragem  $k$ ,  $\hat{y}(k | k-1)$ , a predição da variável  $y$  para o instante  $k$  obtida pela rede neural no tempo de

amostragem anterior ( $k-1$ ) e  $\hat{y}_c(k|k+1)$  é a variável predita corrigida.

### 3.1. Sistema Aberto

As mesmas perturbações propostas para teste do controlador foram impostas ao modelo em malha aberta, utilizando a rotina do modelo fenomenológico. Com isto, espera-se conseguir realizar uma comparação entre os testes com e sem a ação do controlador. Os resultados obtidos do comportamento do modelo sem ação de controle foram agrupados juntos aos resultados obtidos com ação do controlador na forma de gráficos utilizando uma linha pontilhada (Figuras 5 a 8).

### 3.2. Controle Convencional da FCC

Inicialmente, é apresentada uma descrição do controle convencional da unidade FCC, para auxiliar na descrição do processo. A Figura 2 é útil para seu entendimento.

A carga, normalmente proveniente do sistema de tancagem da unidade, apresenta um controle de vazão independente. Ela é aquecida em um forno de aquecimento de carga. A temperatura da carga na saída do forno é controlada por meio de um controle de vazão de combustível para o forno. A temperatura de saída do "Riser" é controlada pela válvula de admissão de catalisador regenerado. O nível de catalisador no vaso separador é controlado pela válvula de catalisador gasto. As temperaturas dos leitos, fases densas e diluídas são controladas pela vazão de ar para regeneração. O diferencial de pressão dos subsistemas reação e regeneração, é controlado pela válvula de gases de combustão.

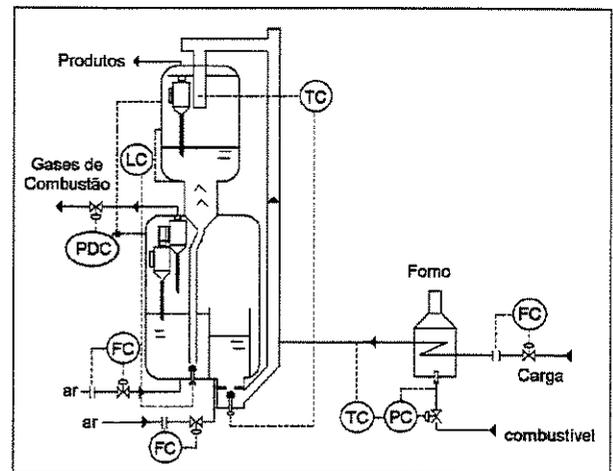


Figura 2 Esquema de controle convencional da FCC.

### 3.3. Controlador Preditivo

A rotina computacional do controlador foi desenvolvida utilizando linguagem Fortran, sendo inserida na rotina do modelo fenomenológico. O processo de minimização da função objetivo foi realizado empregando a rotina *NCONF*, da biblioteca *IMSL*, interna do Fortran. Esta rotina implementa o método de programação quadrática sucessiva (*Successive Quadratic Programming – SQP*) e o método do gradiente por diferenças finitas (*Finite Difference Gradient*), mas não se tem acesso aos programas fontes. No programa foram incluídas as restrições do modelo (Equações 3.1), sendo estas restrições utilizadas também para realizar a estratégia de otimização do controlador. As variáveis manipuladas e controladas foram normalizadas nos mesmos moldes da normalização usada no processo de identificação, (VIEIRA, et al., 2001).

Convém observar que o modelo em redes neurais foi treinado considerando a ação de degraus em cada variável manipulada individualmente, mas o controlador DNC (*Dynamic Networks Control*), prevê a atuação em todas as variáveis manipuladas simultaneamente. O diagrama da Figura 3 mostra um esquema

de um controlador preditivo utilizando RNA.

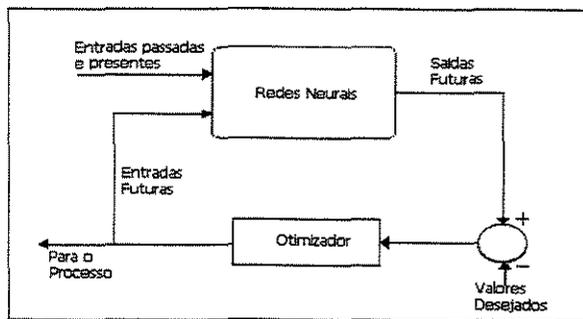


Figura 3 Esquema proposto do Controlador Preditivo com Modelo utilizando redes neurais.

A Figura 4 apresenta um esboço do sistema de controle proposto, já acoplado ao sistema convencional.

A ação do controlador pode ser obtida juntamente com estratégias de otimização da planta. Estas estratégias são obtidas por ações externas, onde se determina qual variável será manipulada alterando-se os seus limites de restrição. Dentre as estratégias de otimização que apresentam interesse, duas se destacam: primeiro a estratégia de maximizar ou minimizar a produção da unidade, variável RTF; em segundo, a estratégia de alterar o objetivo da unidade, passando a produzir GLP ao invés de Nafta, alterando-se o *set point* da variável TRX.

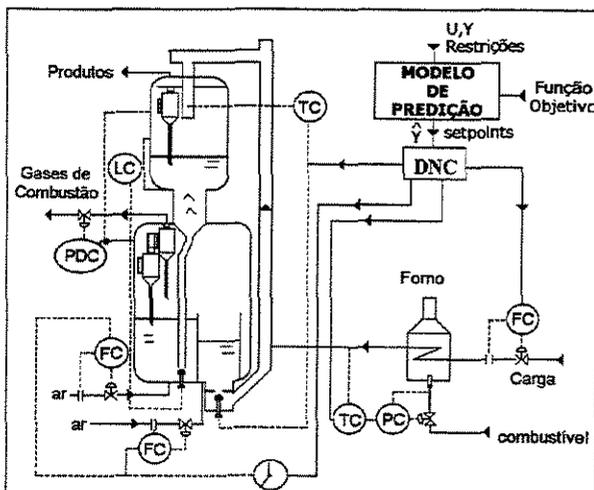


Figura 4 Esboço do controle proposto, via RNA, para acoplamento ao controle convencional da FCC.

Na simulação matemática obtida através do modelo fenomenológico (ODLOAK, 1997) foram obtidos os dados das variáveis controladas e manipuladas que compõem as entrada para o controle DNC. De posse desses dados é chamada a rotina de otimização onde são feitas as previsões das ações nas variáveis manipuladas. A RNA é usada para prever as respostas dessas ações nas variáveis controladas em todo horizonte de previsão ( $N_p$ ). Os resultados dessas previsões resultam nas ações do controlador, em todo horizonte de controle ( $N_c$ ). Seleccionadas as ações que minimizam as diferenças entre as trajetórias de referência no horizonte de controle, a primeira ação do controlador é então enviada de volta ao programa do modelo fenomenológico gerando os dados de impressão de resultados, ficando o programa de controle aguardando novo instante de amostragem, repetindo o ciclo.

Como teste do controlador DNC, foram simulados 1000 minutos de operação, com ação do controlador à partir do minuto 100 sendo inserido uma perturbação a partir do instante 400 minutos. O programa simulador (modelo fenomenológico) se inicia em uma condição fora do estado estacionário, denominada de condição inicial de operação; portanto, após início da ação de controle, tempo 100 minutos, o controlador inicia uma ação de levar as variáveis controladas para o seus "set points". Isto justifica a alteração observada em todos os gráficos no intervalo entre 100 minutos e 400 minutos, instante da perturbação.

#### 4.RESULTADOS

Para o teste considerando o problema regulador é proposto aplicar um degrau na variável temperatura do ar para o regenerador, variável TAI, alterando seu valor em +8%. Foi considerado amostragem de 4,0 em 4,0 minutos, com  $N_p$  igual a 10, e  $N_c$  igual a 1. Os fatores de

ponderação,  $\lambda_i$ , que restringem as ações nas variáveis manipuladas foram:  $1,0E-3$  para TFP,  $3,0E-4$  para RAI,  $6,0E-4$  para RTF, e  $5,0E-2$  para CTCV; e os fatores de igual importância,  $\alpha_i$ , que controlam a relevância de cada variável controlada, foram:  $1,0E-3$  para TRG1,  $1,0E-5$  para TRG2,  $1,0E-4$  para SEV e  $5,0E-3$  para TRX. O filtro utilizado para a trajetória de referência foi de  $9,0E-1$ , para todas as variáveis e a estratégia de otimização considerada para o teste foi a de manter fixa a vazão de carga da unidade, variável RTF.

Os gráficos das Figuras 5 a 12 mostram as respostas à perturbação na

variável TAI; estas respostas são apresentadas em forma comparativa entre a resposta do sistema em malha aberta (linha pontilhada) e com atuação do controlador (linha cheia). A elevação de TAI implicou em uma elevação imediata de TRG1 e TGR2, resultando na elevação da temperatura do catalisador regenerado que por sua vez elevou também TRX e SEV. Estes aumentos foram corrigidos simultaneamente por ação do controlador que reduziu gradualmente a vazão de ar, a abertura da válvula de catalisador regenerado e a temperatura da carga. A vazão de carga (Figura 11) foi mantida fixa conforme foi definido.

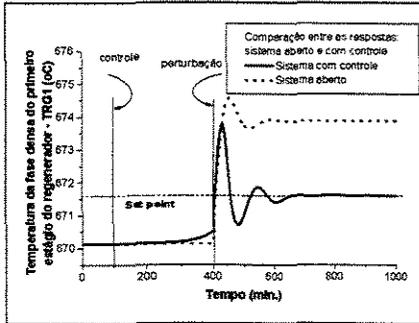


Figura 5. Variável controlada: TRG1. Perturbação: temperatura do ar para o regenerador, TAI.

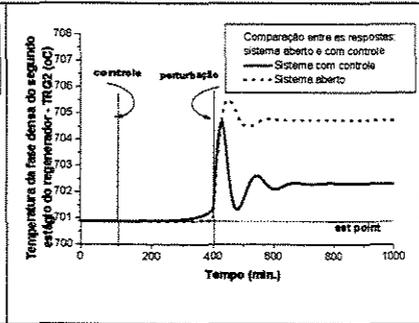


Figura 6. Variável controlada: TRG2. Perturbação: temperatura do ar para o regenerador, TAI.

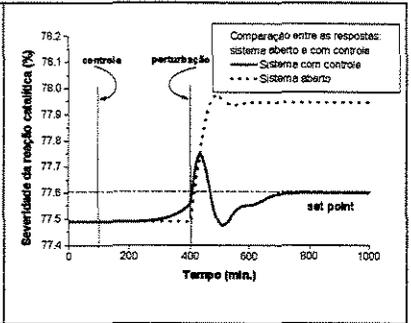


Figura 7. Variável controlada: SEV. Perturbação: temperatura do ar para o regenerador, TAI.

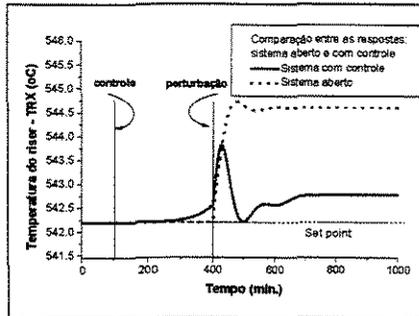


Figura 8. Variável controlada: TRX. Perturbação: temperatura do ar para o regenerador, TAI.

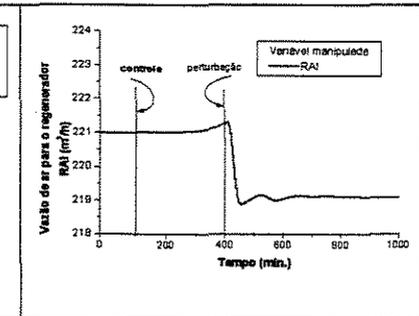


Figura 9. Resultado da ação do controlador na variável RAI. Perturbação: temperatura do ar para o regenerador, TAI.

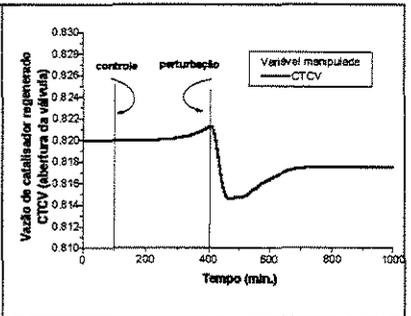


Figura 10. Resultado da ação do controlador na variável manipulada CTCV. Perturbação: temperatura do ar para o regenerador, TAI.

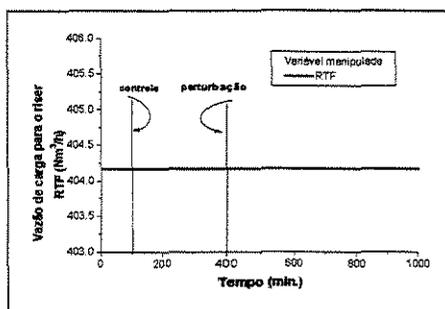


Figura 11. Resultado da ação do controlador na variável RTF. Perturbação: temperatura do ar para o regenerador, TAI.

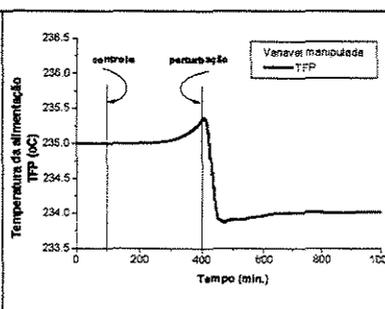


Figura 12. Resultado da ação do controlador na variável TFP. Perturbação: temperatura do ar para o regenerador, TAI.

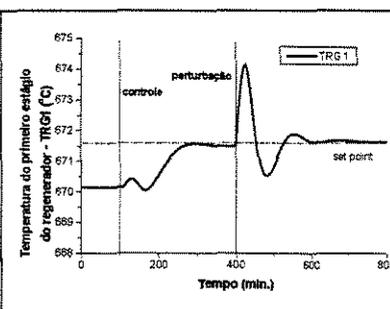


Figura 13 Variável controlada: TRG1. Perturbação na variável TAI, e ruído de 1,5% nas variáveis controladas. Otimização: maximizar GLP.

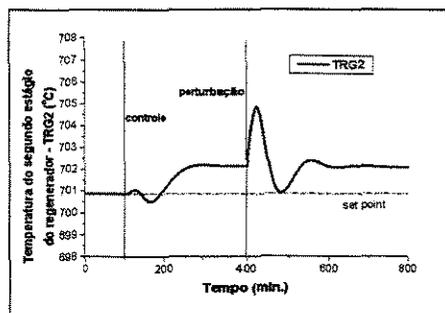


Figura 14 Variável controlada: TRG2. Perturbação na variável TAI, e ruído de 1,5% nas variáveis controladas. Otimização: maximizar GLP.

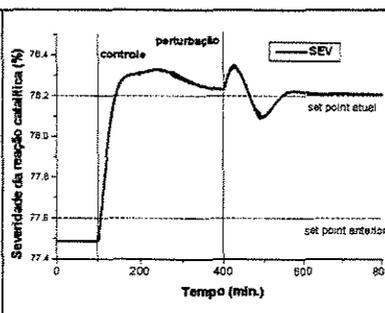


Figura 15 Variável controlada: SEV. Perturbação na variável TAI, e ruído de 1,5% nas variáveis controladas. Otimização: maximizar GLP.

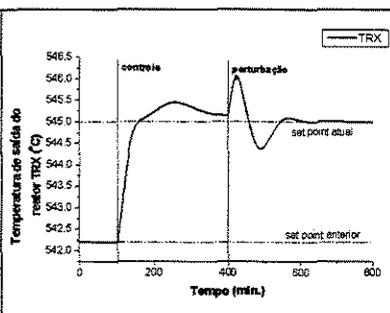


Figura 16 Variável controlada: TRX. Perturbação na variável TAI, e ruído de 1,5% nas variáveis controladas. Otimização: maximizar GLP.

Analisando as Figuras 6 e 8, observa-se que as variáveis TRG2 e TRX se apresentaram ligeiramente acima dos seus *set points*. Na variável TRG2, isto é justificado devido à relação entre a vazão de ar entre primeiro e segundo estágios do regenerador ser mantida fixa, não sendo possível controlar uma variável independente da outra; na variável TRX observa-se uma interdependência entre esta variável e a severidade da reação catalítica; mas apesar deste afastamento, estes resultados foram considerados bons.

Conforme informações obtidas, (ODLOAK, 2001), a unidade FCC frequentemente precisa alterar a estratégia de produção para atender solicitações de mercado. Desta forma, foi efetuado um teste simulando a mudança de produção de

Nafta para GLP, e além disso, foi imposto um degrau na variável perturbação, variável TAI, de intensidade +8%. Para representar a produção de mais GLP, foi elevado o *set point* de TRX da seguinte forma: um degrau nas variáveis severidade da reação catalítica de +0,77% e em TRX de +0,51%. Os gráficos das Figuras 13 a 16 apresentam os resultados obtidos desta simulação nas variáveis controladas. Como as variáveis controladas TRX e severidade da reação catalítica estão interrelacionadas, uma mudança no *set point* de uma delas necessariamente irá afetar a outra, para atender à nova condição de equilíbrio.

Neste último teste, um ruído de intensidade 1,5% foi inserido nos sinais das variáveis controladas antes da entrada do programa de otimização, na tentativa de aproximar o simulador das condições reais de operação; ainda assim, a rede foi capaz

de prever o comportamento do modelo para todas as quatro variáveis envolvidas no processo.

O controle DNC proposto apresentou bom desempenho em todas as situações testadas, apesar de considerar  $N_c$  igual a 1, quer seja no controle levando as variáveis para o *set point* ou na otimização onde se associa o controle com uma busca de determinada condição operacional. Acredita-se que elevando o horizonte de controle para  $N_c > 1$ , os resultados serão ainda melhores, reduzindo o tempo de resposta do controlador; isto ainda não foi conseguido devido à extrema dificuldade de ajuste do controlador multivariável DNC.

## 5. BIBLIOGRAFIA

- AGUILAR, R., GONZÁLEZ, J., RAMÍREZ, J. A., BARRÓN, M. Control of fluid catalytic cracking unit based on proportional-integral reduced order observers. *J. Chem. Engng.* v. 75, p. 77-85, 1999.
- ANSARI, R. M. & TADÉ, M. O. Constrained nonlinear multivariable control of a fluid catalytic cracking process. *J of Proc Cont* v.10, p. 539-555, 2000.
- DE SOUZA JR, M. B. Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos. *Rio de Janeiro: COPPE/UFRJ.* 1993. 124 p. *Tese (doutorado)*
- FILETI, A. M. F. Controle avançado de Processos: Adaptativo, Preditivo e Fuzzy. Modelagem Matemática via Redes Neurais. Aplicações em Processos Químicos. (*curso ministrado na Escola Politécnica da Universidade Federal da Bahia*). 1998.
- KURIHARA H. Optimal Control of Fluid Catalytic Cracking Processes. *MIT: Science Dr. Thesis*, 1967. *Tese (doutorado)*
- MORO, L. F. L. Desenvolvimento de um Controlador Preditivo Multivariável para um Conversor Industrial de Craqueamento Catalítico. *São Paulo: USP, 1992, 77 p. Dissertação (Mestrado)*
- NARENDRA, K. S. Neural Networks for Control: Theory and Practice. *Proc. of IEEE*, v. 84, n. 10. Oct 1996.
- NARENDRA, K. S. and MUKHOPADHYAY, S. Adaptive Control Using Neural Networks and Approximate Models. *IEEE Trans. on N. Net.*, v. 8, n. 3, May 1997.
- ODLOAK D., MORO L. F. L., GOUVEA M. T. – Programa para simulação dinâmica e controle DMC em linguagem FORTRAN. Comunicação pessoal. 1997.
- ODLOAK, D. Comunicação pessoal 2001
- SANTOS, V. M. L. Identificação e Controle Preditivo Baseado em Redes Neurais de Processos de Craqueamento Catalítico em Leito Fluidizado. *Recife, PE: DEQ/UFPE, 101p. 2000b. dissertação (mestrado)*
- VIEIRA, W.G., FILETI, A.M.F., CARVALHO, F.R., PEREIRA, J.A.F.R. FCC: Process Identification Through Artificial Neural Networks. *Proceedings of 6<sup>TH</sup> World Congress of Chem Engng. Australia. 2001.*
- WANG, H., OH, Y. and YOON, E. S. Strategies for Modeling and Control of Nonlinear Chemical Processes using Neural Networks. *Comp. Chem. Engng.* v. 22, *Suppl.*, p. S832-S862, 1998.
- ZANIN, A. C., M. TVRZSKÁ de GOUVEA, M. AND ODLOAK, D. Industrial implementation of a real-time optimization strategy for maximizing production of LPG in a FCC unit. *Comp and Chem Engng* 24 pp. 525-531. 2000
- ZHAN, J. & ISHIDA, M. The Multi-step Predictive Control of Nonlinear SISO Processes with a Neural Model Predictive Control (NMPC) Method.

*Computers chem. Engng.*, v. 21, n. 2,  
p. 201-210, 1997.

## FCC: Process Identification Through Artificial Neural Networks

Vieira, W.G.<sup>1</sup>; Fileti, A.M.F.<sup>2\*</sup>; Carvalho, F.R.<sup>3</sup>; Pereira, J.A.F.R.<sup>2</sup>

<sup>1</sup>CTEC/DEQ - Universidade Federal de Alagoas

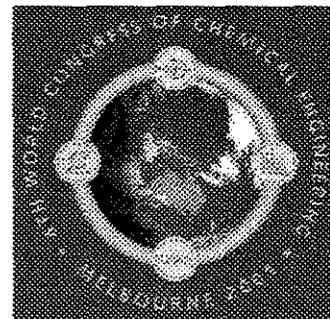
Maceió - AL - Brasil 57072-970 e-mail: [wgv@npd.ufpe.br](mailto:wgv@npd.ufpe.br)

<sup>2</sup>DESQ/FEQ - Universidade Estadual de Campinas

Campinas - SP - Brasil 13083-970 e-mail: [frattini@desq.feq.unicamp.br](mailto:frattini@desq.feq.unicamp.br)

<sup>3</sup>CTG/DEQ - Universidade Federal de Pernambuco

Recife - PE - Brasil 50740-521 e-mail: [florival@npd.ufpe.br](mailto:florival@npd.ufpe.br)



This paper describes an identification procedure, based on ANN, of a Fluid Catalytic Cracking converter. A phenomenological model, validated with real operation data, was used to generate a large data set of operational variables. Using the first principles model, an initial steady-state was achieved and several steps were applied to the manipulated variables. Three groups of data were respectively generated for training, validation and testing. A multilayer feedforward network was chosen for the FCC representation. Two different strategies were adopted for the network architecture: first, the input layer is composed by one manipulated variable, and in the second structure, is composed by four manipulated variables. The output layer was formed by the four controlled variables. The number of nodes in the hidden layer was obtained from a trial-and-error procedure. It was observed that the network generalization capacity and the training time increased with the number of hidden neurons. From the results, the architectures chosen for the FCC neural modeling were 5x15x4 and 8x15x4 and convergence criteria of  $10^{-3}$  was used. In all tests, the relative error of the output variables was below 1%. As a result, reliable neural models were developed for the process identification and they could be used in a model predictive control structure for the FCC converter control.

## INTRODUCTION

The use of complex and more precise mathematical methods in systems engineering has been extensively encouraged by the introduction of low cost digital computers and high-speed processing. This new technology allows the artificial neural networks methodology to be extensively used for the identification and control of chemical systems.

Any linear or non-linear chemical process can be simulated through a neural network modeling, even when the first principles of the process are unknown. Just input/output operational data is needed [1].

Several researches were already made based on ANN: Narendra [2], summarizes the application of ANN in Process Control and describes the last advances in this area. The author compares ANN's mathematical bases and some successful industrial applications are mentioned. In the processes identification area, Nikravesh [3] applied the backpropagation training procedure to a CSTR reactor.

De Souza Jr. [4] employed an ANN for process classification, where the network was used to predict the properties of a catalyst in function of the conditions of the manufacture process. The author also used the network for the identification of nonlinear reactors within a predictive control loop. Santos [5] reports the application of an ANN for FCC identification and control, using two different process models: a simplified model side-by-side and a more complex one, already validated with the data of the industrial unit. The study was restricted to a SISO structure (Single Input and Single Output).

The FCC unit is one of the most important processes in oil refineries for the largest yield of products reached and the importance of them. A small benefit in this process is economically attractive. Moreover, the environmental regulations related to gas emissions like CO, CO<sub>2</sub>, NO<sub>x</sub>

\* Whom all correspondence should be addressed.

and  $\text{SO}_x$ , are to date, very important. Therefore, advanced process control may be needed. However, FCC units are process physically complex and prove several difficulties to operate and control. The regenerator and the reactor sections of FCC units are highly interactive with difficult dynamics. The process is poorly known mainly because of the complexity of the chemical kinetics. In practice, FCC units are frequently regulated by means of standard PID controllers and also through manual control actions based on the knowledge of the refinery operators.

A nonlinear constrained optimization strategy was proposed by Ansari and Tadé [6] and applied to the FCC unit. A nonlinear dynamic model of the FCC process was used for the dynamic analysis of the plant and for tests of a nonlinear multivariable control system. The model were tested in a real-time application and the results were used to provide the initial values for the nonlinear control system design. A dynamic parameter update algorithm was used to reduce the effect of large modeling errors by regularly updating the model parameters. The constrained nonlinear optimization algorithm was real-time tested on the FCC reactor-regenerator. The results compared favorably to those from a linear multivariable controller.

Wang et al. [7,8] proposed a study using wavelet functions and neural networks for the FCC process identification. Aguilera et al. [9] deal with the regulatory control law design for stabilization of the reactor and regenerator temperatures of a FCC unit, considering the kinetics terms poorly known. The proposed control law uses on-line estimates of the input/output modeling errors, obtained from a proportional-integral reduced order observer. The structure of the proposed controller is similar to a proportional-double integral compensator ( $\text{PI}^2$ ) since a new parameterization of the controller gains is given in terms of the closed-loop and estimated time constants. The performance of the control scheme proposed is analyzed via numerical simulations. Still concerning about FCC control, Antoniadis and Christofides [10] proposed a methodology for the synthesis of nonlinear output feedback controllers for SISO nonlinear Differential Difference Equation (DDE) systems which include time delays in the control actuator and in the measurement sensor. The proposed control method was successfully applied to a FCC and it is shown to outperform nonlinear controller designs that do not account for the presence of dead time associated with the recycle loop and the pipes transferring material from the reactor to the regenerator and vice-versa.

Zanin et al. [11] described the implementation of a new non-conventional real-time optimization strategy applied to the maximization of LPG production in a (FCC) converter in the refinery of São José dos Campos in Brazil. Focus was given on the difficulties of integrating optimization to existing controllers. The first commissioning tests was described in detail. They showed that the benefits from optimization are not restricted to economic values. Implementation of the strategy gives directions on how to change the operating mentality of the plant operators. The implemented optimization strategy was shown to be able to maintain control of the plant even in the loss of several manipulated variables and in the presence of strong disturbances. Furthermore, it was shown that the optimization strategy is able to drive the process to new operational points. Sarma and Rengaswamy [12] used a systematically constructed chain of gain-scheduled fuzzy logic controllers (GS-FLCs), using sigmoidal gain-schedule (SGS). The SGS simultaneously has a crisp and intuitive gain-like format, and together they get relatively simple heuristic tuning for the GS-FLC. This nonlinear GS-FLC structure permits the use of a very simple static linear decoupler (SLD). This control technique was applied in a FCC unit, and the general multivariable GS-FLC/SLD system demonstrates very good controller performance, covering servo/regulatory and robustness tests.

From the above, the FCC control problem has been widely addressed through several methodologies. An identification procedure based on neural networks may provide the FCC control designer a better understanding on the process dynamics and could be useful as an internal model for a Predictive Control scheme. The Model Predictive Control is based on a general performance index and parameterization of the control variables in a non-linear model, with includes the relevant constraints [13,14,15]. The FCC process represents a challenge environment where substantial benefits for process industry and for control theory could be achieved.

In this work, the development of a FCC modeling using ANN is described. This model is supposed to represent a strongly nonlinear process, with operational restrictions that involves a

MIMO system (Multiple Input and Multiple Output). Besides the process nonlinearity and operational restrictions, high interaction degree between its variables is described. The case study chosen for the present development is the Fluid Cracking Catalytic Unit (FCC) of the Henrique Lage refinery – REVAP (São José dos Campos, SP, Brazil), through its respective model: Kellogg Orthoflow F. Moro [16] presented the phenomenological modelling of the Henrique Lage Refinery FCC unit. This model was validated with the operational data of the industrial unit. In order to train the ANN, a numerical simulator based on this phenomenological model will be used in the present work to generate large data set of operational variables. Different networks architectures are proposed to represent the FCC process.

#### *PROCESS DESCRIPTION*

The Fluid Catalytic Cracking (FCC) unit represented by the Kellogg Orthoflow F. model of the Henrique Lage Refinery of Petrobrás was the process chosen for this study. The converter is supposed to reduce the size of the hydrocarbon chains of the heavy petroleum fractions through catalytic reactions. This process is extremely important because derived products of petroleum of high molecular weight (that possesses little application and therefore lower commercial value) are transformed in products of higher commercial values. The FCC unit inlets are the outlets of the following units: Vacuum Distillation (Gas-oil and Vacuum Residue) and Unit of Treatment with Propane (Heavy Oil). As products, it is obtained: Fuel Gas, Liquefied Gas of Petroleum (GLP), Cracked Naphtha, Light Cycle Oil (LCO), Decanted Oil (also denominated Fuel Oil of FCC or Cracked Fuel Oil) and Coke. These high-value products are called Cracked Naphtha, mainly used as automotive gasoline. High temperature is needed (from 500°C to 550°C) in presence of a selective catalyst. The catalyst is used in the form of a white powder with high porosity and specific area. Because of the small dimensions, it flows as if it was a fluid. Due to the operational temperature range, undesirable secondary reactions occur, such as coke formation, polymerization and dehydrogenating. As a consequence coke deposition on the surface of the catalyst occurs and therefore the catalyst activity is reduced.

The unit is composed of two sections: one of catalytic reaction, where the reactions of chain break and also coke deposition on the catalyst take place; and the other, where burn of the coke occurs, regenerating the catalyst (see Fig. 1). Then the catalyst is forced to pass from the reaction section to the regeneration section, and finally coming back for the reaction section (see Fig. 2). The regeneration reaction is carried out through air injection and burning in the regenerator.

Due to the extremely severe conditions of operation, rigorous control of some operational variable (controlled) is needed. Several variables can be taken as controlled in the industry. In this study the following variables will be used: temperature of cracking mixture in riser (TRX), temperature of dense phase at regenerator first and second stages (TRG1 and TRG2) and conversion of the reactor (Severity of the cracking reaction). The following variables will be manipulated: total feed flowrate to riser (RTF), regenerated catalyst valve opening (CTCV), air flow rate to regenerator (RAI) and feed temperature at riser entrance (TFP). Besides these variables, the process requires the maintenance of other variables between their restriction limits, such as: differential pressure on the reactor level control valve, temperature of the regenerator first stage dilute phase and temperature of the regenerator global dilute phase.

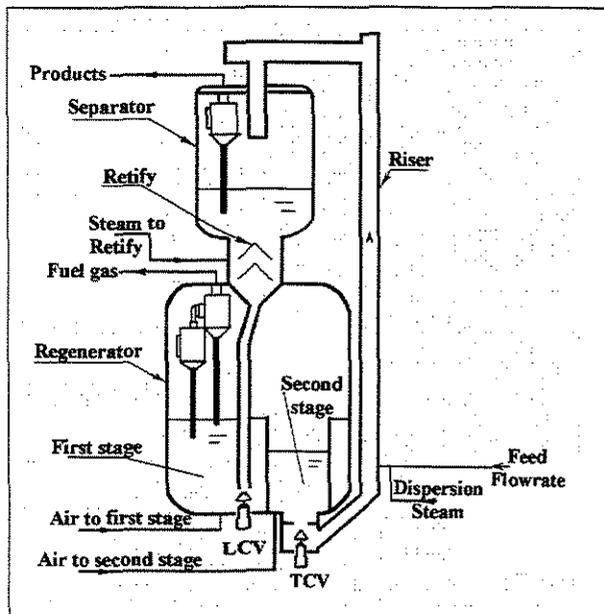


Fig. 1 Schematic draw of the FCC of Henrique Lage Refinery.

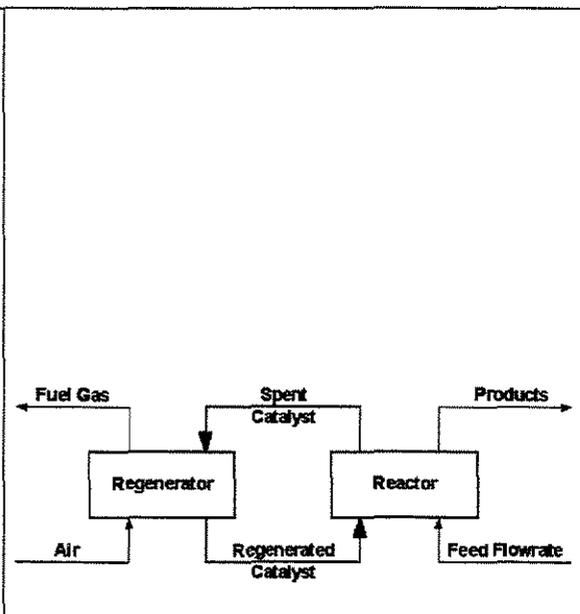


Fig. 2 Schematic draw of the catalyst circulation.

## METHODOLOGY

### Neural Networks

The ANN are formed by processors elements denominated of neurons or nodes, interconnected by channels called of connections, forming a dense net [4, 17]. The nodes are arranged in layers linking the input with the output. The connections tie the nodes of one layer with the nodes of another one. The way as the nodes are connected and their disposition determine the architecture of the network. In the present study the net was configured as multilayer feedforward fully connected, with one hidden layer and without feedback connections. Hidden layers are used to extract, from the network, statistical results of high order [17].

Mathematically, the behavior of a neuron in a generic layer can be represented by:

$$\lambda_{pj,k+1} = \left[ \sum_{i=1}^{n_k} w_{jik} S_{pi,k} \right] + \theta_{j,k+1}, \quad (1)$$

where:  $\lambda$  represents the output of the neuron ' $j$ ', in the layer ' $k+1$ ';

$S$  corresponds to the outputs or activation of all neurons of the layer ' $k$ ';

$w$  is the weight of the connections;

$\theta$  is the internal limit of activation of the corresponding neuron ' $j$ ' (bias).

An activation function, called transfer function of neuron, is applied to  $\lambda$ . In the present study was used the sigmoid function, defined by:

$$f(\lambda_{pj,k+1}) = \left[ 1 + \exp(-\lambda_{pj,k+1}) \right]^{-1} \quad (2)$$

The learning procedure is the process where the weights and biases are modified [18]. The supervised training was used in this work. Known input and output data (patterns) are presented to the network. The network is then adjusted by changing the weights and bias with predefined rules. The patterns are initially normalized to avoid differences in the magnitude order of the input and

output [19]. Due to the use of the sigmoid as transfer function, the normalization was made to obtain the patterns in the positive interval between 0.0 and 1.0. Indeed it was chosen a limit interval among 0.1 to 0.9 to allow, if necessary, small extrapolations [5]. The following relationship is used for the normalization procedure:

$$P_{nor} = 0.1 + \left( \frac{P_{real} - P_{min}}{P_{max} - P_{min}} \right) \times 0.8, \quad (3)$$

where:  $P_{nor}$  represents the normalized pattern;

$P_{real}$  is pattern in the units of input/output and is obtained from the phenomenological model;

$P_{min}$  is the lower bound of the variable;

$P_{max}$  is the upper bound of the variable.

The initial weights and biases were selected through a random routine that generates numbers between -1.0 and +1.0. The Training Algorithm used was Backpropagation, based on the error correction technique. In the optimization process, the strategy of the steepest descent was used [4, 17].

#### Obtaining the data set

The phenomenological model developed by Moro [16], which represents the FCC unit, was used to generate the process data for training and testing the neural model.

Through the use of numerical simulations based on the phenomenological model, a initial steady state was first achieved. Several steps were then applied in the manipulated variables and the response of the controlled variables monitored. It was observed that the time spent on training the networks is straightly dependent to the number of steps applied to the manipulated variable. On the other hand, a very low number of steps could be insufficient to represent the operational range of the process. Indeed there must be a compromise between the number of steps to be implemented and the total variation allowed to the manipulated variables. The range recommended by Moro was used: 1.5kNm<sup>3</sup>/h in RAI variable, 0.003units in CTCV variable, 50.0m<sup>3</sup>/d in RTF variable and 2.2°C in TFP variable. The time interval between two successive steps should be large enough for the process to reach a new steady state before the following step. Table 1 presents the manipulated variables and the respective size of the imposed steps and the time interval between them.

Table 1 Manipulated variables, and their respective imposed perturbation.

Manipulated variables	TRAINING AND VALIDATE SET			TEST SET		
	Step (%)	Step time (min.)			Step (%)	Step time (min.)
CTCV	-7,-12,-5,+2,+11,+4, 0	270,300,300,300,600,600,300			+2.5,-2.5,0	320, 350, 350
RAI	-5, -9, -3, +1, +4, 0	570, 600, 900, 600, 600, 300			+2.5,-2.5,0	320, 350, 350
RTF	-6, -10, -4, +2, +7, 0	270, 300, 300, 300, 300, 300			+1.5,-1.5,0	320, 350, 350
TFP	-5, -8.5, -3, +1, +4, 0	270, 300, 300, 300, 300, 300			+2.5,-2.5,0	320, 350, 350
CTCV;	-7,-12,-5,+2,+11,+4,0,	270,300,300,300,600,600,300,			+2.5,-2.5,0,	320, 350, 350,
RAI;	-5, -9, -3, +1, +4, 0,	600, 600, 900, 600, 600, 300,			+2.5,-2.5,0,	350, 350, 350,
RTF;	-6, -10, -4, +2, +7, 0,	300, 300, 300, 300, 300, 300,			+1.5,-1.5,0,	350, 350, 350,
TFP	-5,-8.5, -3, +1, +4, 0	300, 300, 300, 300, 300, 300			+2.5 -2.5,0	350, 350, 350

The data obtained from the phenomenological model was split in 3 sets: training set (if these values were used for the learning procedure), validation set (if used for validation of the trained networks) and test set (if used for final test of the neural model). These data sets were obtained under specific conditions, namely:

- Training set: samples were taken every 6 min., starting in the 4<sup>th</sup> minute; time interval between two successive steps (see Tab. 1).
- Validation set: samples were taken every 2 min., starting in the 4<sup>th</sup> minute; time interval between two successive steps (see Tab. 1).
- Test set: samples were taken every 1 min., starting in the first minute; time interval between two successive steps (see Tab. 1).

All these sets were obtained after initial steady state is reached (30min.).

It should be noted that the sequence of steps in the test set is different from the sequence of the steps imposed for training and validation sets.

#### *Training the ANN*

With data sets obtained from rigorous numerical simulations, the learning procedure started. A fully connected multilayer feedforward network was chosen for the FCC representation. Two different structures were adopted for the network architecture: first, the input layer is composed of one manipulated variable and four controlled variables, and in the second structure, is composed of four manipulated variables and four controlled variables. The output layer was formed by the four controlled variables.

The number of nodes in the hidden layer was obtained from a trial-and-error procedure. Increasing the number of nodes in the hidden layer leads to better results and smaller training time than that required with the increase of the number of hidden layers. Hiecht-Nielsen [20] had already proven that any continuous function can be mapped with the architecture of 3 layers. However, there must be enough neurons in the hidden layer. Therefore the use of more than one hidden layer was abandoned.

Once determined the network architecture, it was performed a study seeking to define the minimum number of patterns to be presented to the network during the training procedure. Special care was taken in order to choose data that covers the whole operational range of the variables.

Initially an excessive number of training patterns (over 5000) were used. Convergence was just reached when this number was reduced for less than 1500 patterns, but it also depends on the precision and on the number of nodes in the hidden layer. Target convergence criteria ranging from  $10^{-9}$  to  $10^{-3}$  in the gradient of the objective function was used. A number of nodes of 1, 2, 3, 4, 5, 6, 10, 15 and 20 was tested in the hidden layer. A relative error close to 1% between the results of the model and the results of the network was considered enough for acceptance of the training procedure.

## RESULTS AND CONCLUSIONS

### ANN Modeling

Table 2 shows the CPU time consumed on the training procedure with a PC Pentium II 400 MHz. It also shows the convergence criteria used and the minimum value obtained for the objective function. Both structures described on item "Training the ANN" were tested.

Table 2. Training time, precision and objective function obtained.

Manipulate variable	CPU Time (min)	Convergence Criteria	Objective function
<b>First structure</b>			
CTCV	320	8,49E-4	1,61E-1
RAI	685	6,86E-4	8,26E-2
RTF	356	7,81E-4	3,56E-2
TFP	1029	4,37E-4	2,07E-2
<b>Second structure</b>			
CTCV, RAI, RTF, TFP	2589	5,26E-4	1,09E-1

After training, the network validation was performed with the validation data set. The step sequence was changed. In this test, in the attempt of simulating the conditions closer to the reality of an industrial unit, random noises were added to all the controlled variable signals.

With reduced number of nodes (1 to 5) and using a target convergence criteria from  $10^{-9}$  to  $10^{-3}$  in the gradient of the objective function, convergence was not achieved or some process oscillations could not be captured in some tests, resulting a lost of generality. Increasing the number of hidden neurons to 10, 15 and 20, the results were considered acceptable. In order to reduce the time consumed in the training procedure it was necessary a change in the convergence criteria ( $10^{-3}$  and  $10^{-2}$ ). The number of patterns was also reduced (1000 patterns).

The behavior of the controlled variables is presented on Figures 3 and 4 for three steps in the manipulated variable CTCV. The values are shown in a comparative way between network output (with noise) and rigorous model. The architecture  $5 \times 15 \times 4$  and a convergence criterion of  $10^{-3}$  were used. As it can be observed, the relative error between rigorous model and network vanishes for TRG1 and TRG2. For Severity and TRX, the relative errors were approximately 0.15% and 0.1%.

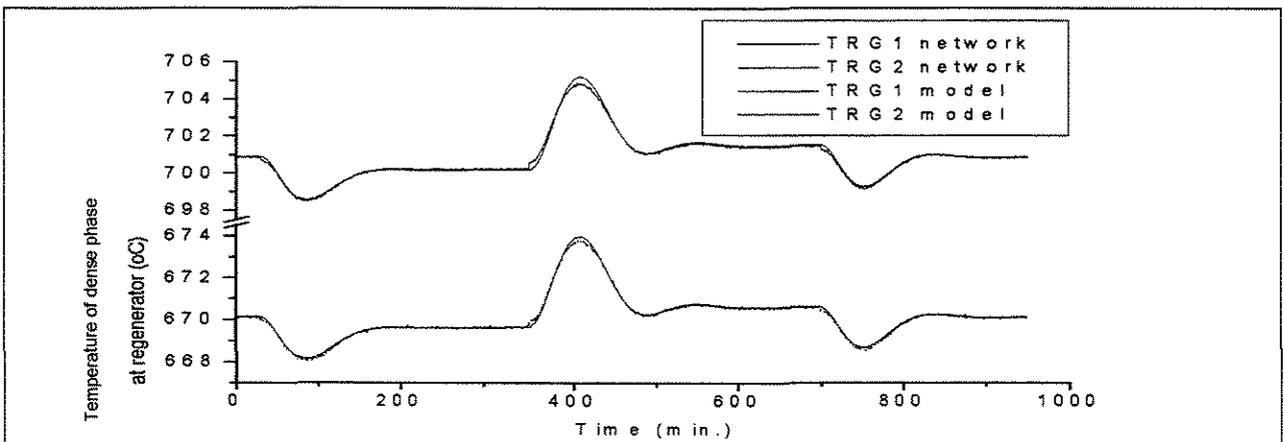


Fig. 3. Comparative response between rigorous model and the neural network model for TRG1 and TRG2 with 3 steps on manipulated variable CTCV.

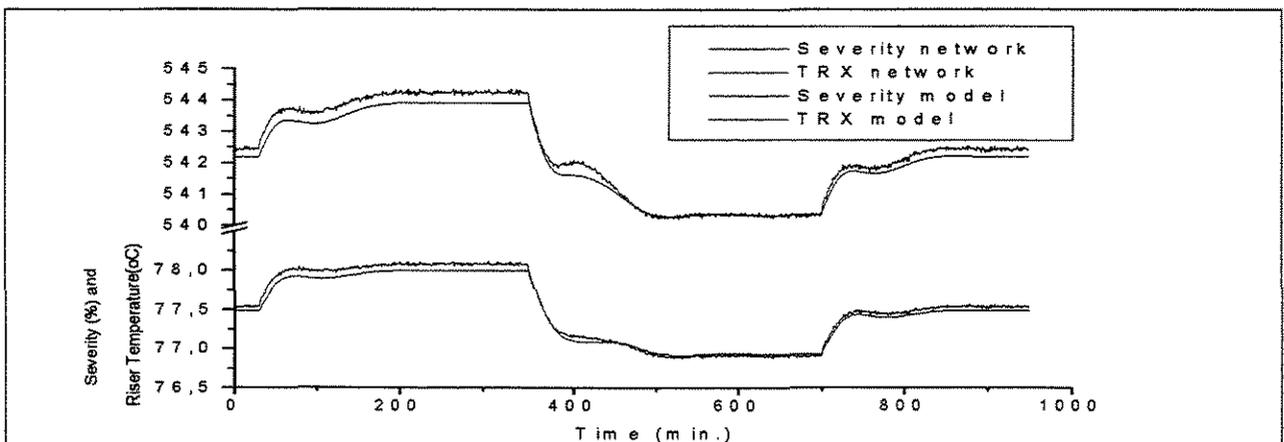


Fig. 4. Comparative response between rigorous model and the neural network model for Severity of the cracking reaction and Riser Temperature with 3 steps on manipulated variable CTCV.

Steps were also imposed to RAI, RTF and TFP variables. The behavior was similar to the previous one and the relative error obtained from the test data set is shown in the dispersion format in the Figures 5 to 10. It should be noted that the sequence of steps in the test set is different from the sequence of the steps imposed for training and validation sets. These Figures shows the agreement between rigorous numerical simulations and the neural model.

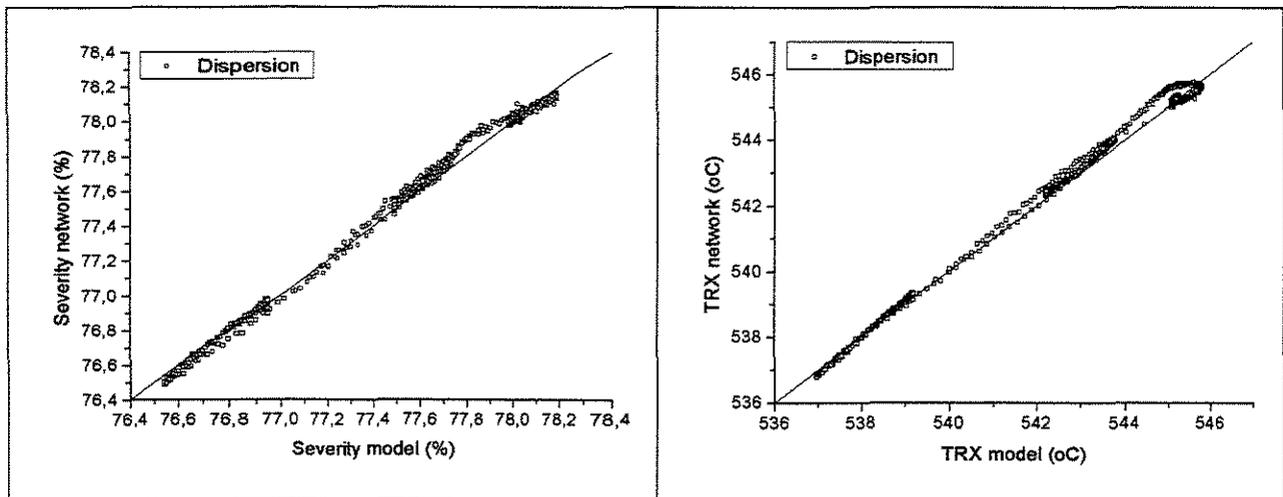


Fig. 5 and 6. Response of relative dispersion between model and network for Severity of cracking reaction and TRX for 3 steps in RAI variable.

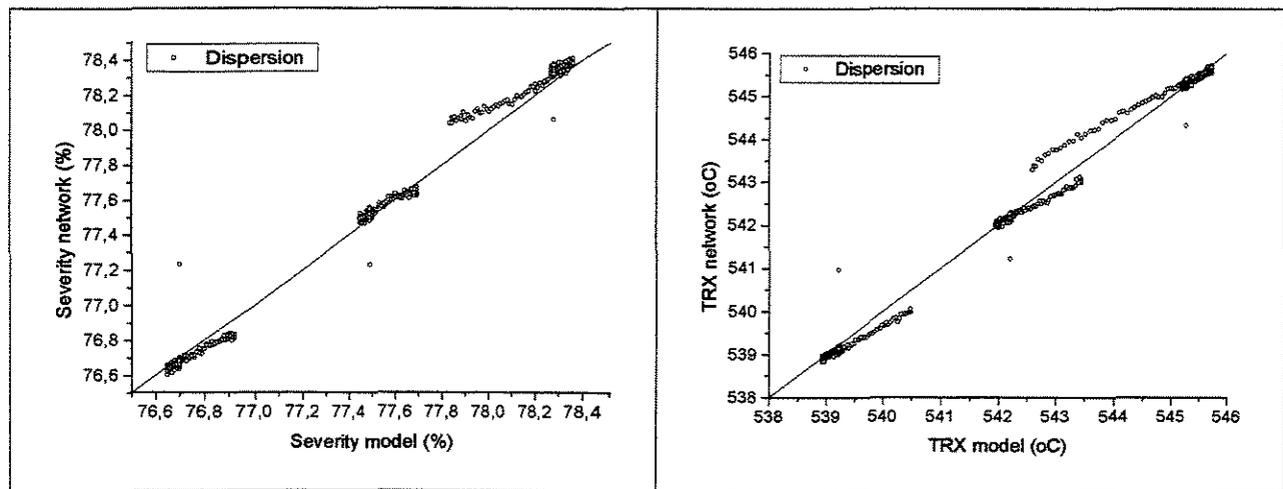


Fig. 7 and 8. Response of relative dispersion between model and network for Severity of cracking reaction and TRX for 3 steps in RTF variable.

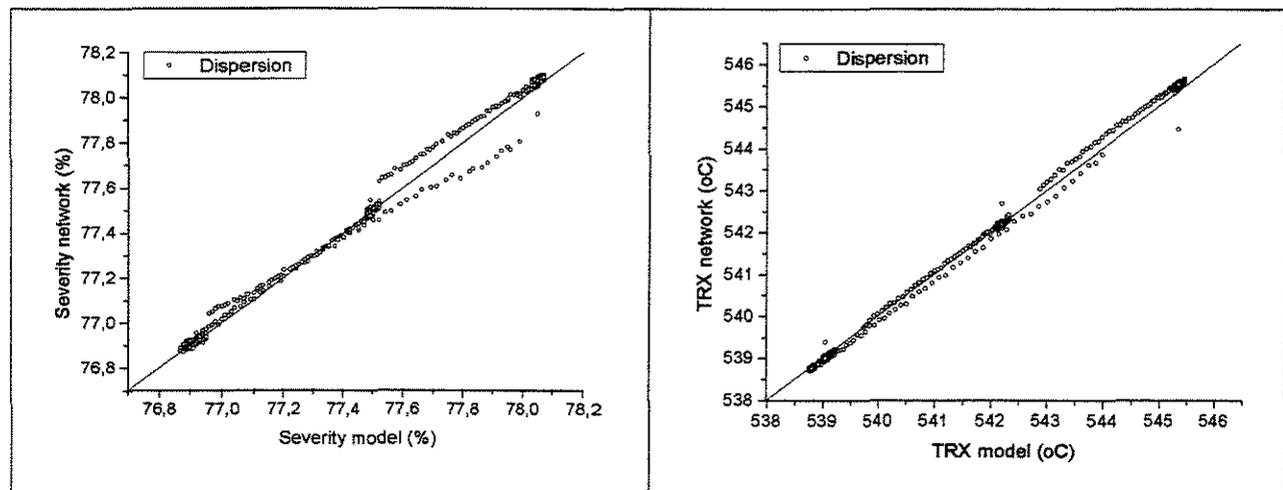


Fig. 9 and 10. Response of relative dispersion between model and network for Severity of cracking reaction and TRX for 3 steps in TFP variable.

The results of the second structure of network (architecture 8x15x4) with convergence criteria of  $10^{-3}$ , are presented in the Figure 11 (Severity of the cracking reaction). The agreement between phenomenological model and network can be better observed in figures 12 and 13.

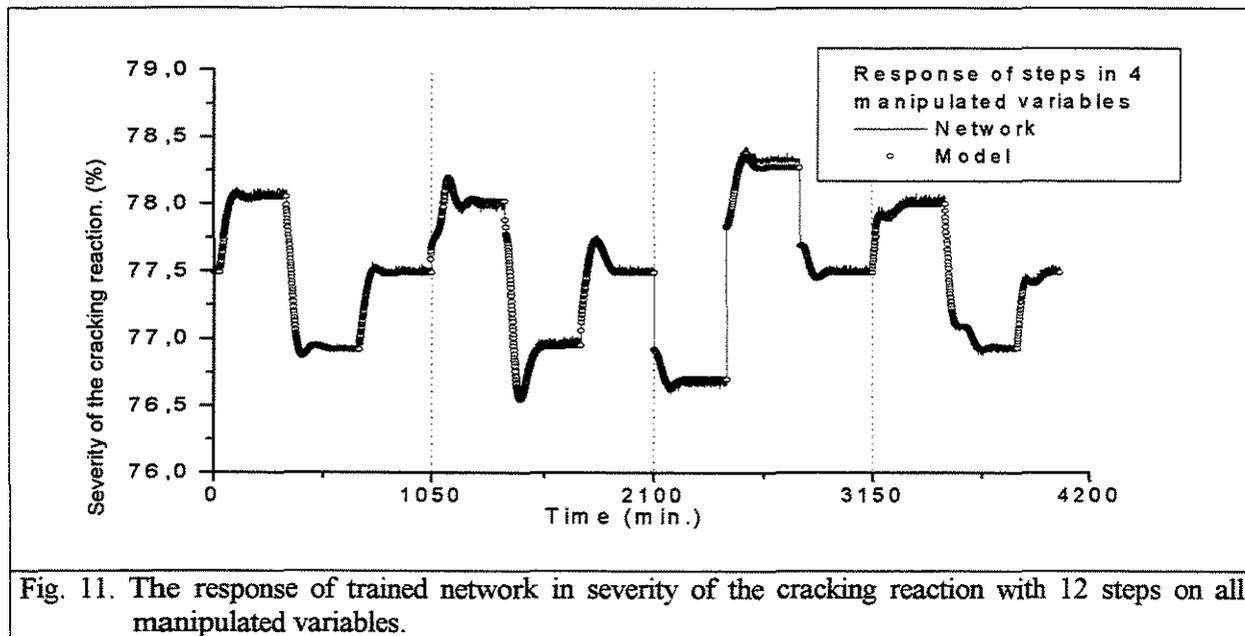


Fig. 11. The response of trained network in severity of the cracking reaction with 12 steps on all manipulated variables.

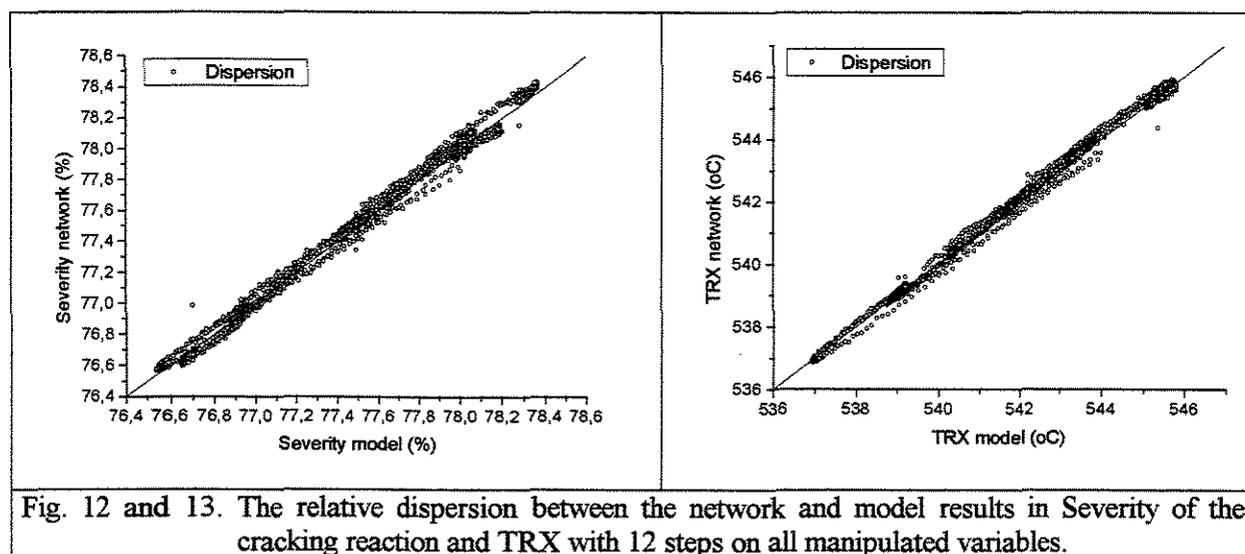


Fig. 12 and 13. The relative dispersion between the network and model results in Severity of the cracking reaction and TRX with 12 steps on all manipulated variables.

From the results, the architectures chosen for the FCC neural modeling were 5x15x4 and 8x15x4. In all tests, the relative error of the output variables was below 1%. As a result, reliable neural models were developed for the process identification and they could be used in a model predictive control structure for the FCC control.

#### FINAL REMARKS

This paper describes an identification procedure, based on artificial neural networks, of a Fluid Catalytic Cracking converter. A phenomenological model, validated with real operation data collected from a Kellogg Orthoflow F. converter, was used to generate a large data set of operational variables. A fully connected multilayer feedforward network was chosen for the FCC representation. Two different strategies were adopted for the network architecture: first, the input layer is composed of one manipulated variable and four controlled variables, and in the second

structure, is composed of four manipulated variables and four controlled variables. The main advantage of neural networks in comparison to the phenomenological model is the CPU processing time. In addition, it was also shown that both proposed structures yield high quality predictions of the controlled variables. From the results, the architectures chosen for the FCC neural modeling were 5x15x4 and 8x15x4. In all tests, the relative error of the output variables was below 1%. As a result, reliable neural models were developed for the process identification and they could be used in a model predictive control structure for the FCC converter control.

## REFERENCES

- 1 Narendra, K. S. & Mukhopadhyay, S., 1997, 'Adaptive Control Using Neural Networks and Approximate Models'. *IEEE Transactions on Neural Networks*, **8(3)**, pp. 475-485.
- 2 Narendra, K. S., 1996, 'Neural Networks for Control: Theory and Practice'. *Proceeding of the IEEE*, vol. **84(10)**, pp. 1385-1406.
- 3 Nikravesh, M. Fareli, A. E. And Stanford, T. G., 1996, 'Model Identification of Nonlinear Time Variant Process via Artificial Neural Network'. *Computers and Chemical Engineering*, **20(11)**, pp. 1277-1290.
- 4 De Souza Jr, M. B. (1993) 'Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos'. Dr. Thesis, COPPE/UFRJ, Brazil.
- 5 Santos, V. M. L., Carvalho, F. R. And De Souza Jr, M. B. (2000) 'Predictive Control Based on Neural Networks: An Application to a Fluid Catalytic Cracking Industrial Unit'. *Brazilian Journal of Chemical Engineering*. **17(04-07)**, pp. 897.
- 6 Ansari, R. M. and Tadé, M. O. (2000) 'Constrained nonlinear multivariable control of a fluid catalytic cracking process'. *Journal of Process Control* **10**, pp. 539-555.
- 7 Wang, X. Z., Chen, B. H., Yang, S. H., C. McGreavy. (1999) 'Application of wavelets and neural networks to diagnostic system development, 1, feature extraction'. *Computers and Chemical Engineering* **23**, pp. 899-906.
- 8 Wang, X. Z., Chen, B. H., Yang, S. H., C. McGreavy. (1999) 'Application of wavelets and neural networks to diagnostic system development, 2, an integrated framework and its application'. *Computers and Chemical Engineering* **23** pp. 945-954.
- 9 Aguilera, R., González, J, Ramirez, J. A., Barrón, M. (1999) 'Control of a fluid catalytic cracking unit based on proportional-integral reduced order observers'. *Journal of Chemical Engineering* **75** pp. 77-85.
- 10 Antoniadis, C., Christofides, P. D. (1999) 'Feedback control of nonlinear differential difference equation systems'. *Chemical Engineering Science* **54** pp. 5677-5709.
- 11 Zanin, A. C., M. Tvrzská de Gouvêa, M. and Odloak, D. (2000) 'Industrial implementation of a real-time optimization strategy for maximizing production of LPG in a FCC unit'. *Computers and Chemical Engineering* **24** pp. 525-531.
- 12 Sarma, P. and Rengaswamy, R. (2000) 'Multivariable gain-scheduled fuzzy logic control of a fluidized catalytic cracker unit'. *Computers and Chemical Engineering* **24** pp. 1083-1089.
- 13 Balchen, J.G., Lungquist D. and Strand S., (1992) 'State-space predictive control', *Chemical Engineering Sci.* **47** pp. 787-798.
- 14 Grosdidier P., Mason A., Aitolahti A., Vanhumaki V., (1993) 'FCC Unit Regenerator/reactor control', *Computers and Chemical Engineering* **17** pp. 165-179.
- 15 Ali, E.E. and Elnashaie, S., (1997) 'Non-linear model predictive control of industrial type IV fluid catalytic cracking (FCC) units for maximum gasoline yield', *Ind. and Engng. Chem. Res.* **36** pp. 389-398.
- 16 Moro, L. F. L. (1992) 'Desenvolvimento de um controlador preditivo multivariável para um conversor industrial de Craqueamento Catalítico'. MSc. Thesis, USP/SP, Brazil.
- 17 Haykin, S. (1994) 'Neural Networks – A Comprehensive Foundation' Macmillan Publishing Co. NJ, 696p.
- 18 Simpson, P. K. (1990) 'Artificial Neural Systems: Foundations, Paradigms, Applications and Implementations'. Pergamon Press, Inc., NY, 203p.

- 19 Baughman, D. R. & Liu, Y. A. (1995) 'Neural Networks in Bioprocessing and Chemical Engineering'. Academic Press, Inc. London, 489p.
- 20 Hecht-Nielsen, R. (1989) 'Theory of the Backpropagation Neural Network', *IEEE Int. Conf. On Neural Networks*, I, pp. 593-605.