

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

William G. Vieira<sup>1</sup>; Ana Maria F. Fileti<sup>2\*</sup>; Florival R. Carvalho<sup>3</sup>

<sup>1</sup>CTEC/DEQ - UFAL, Maceió – AL – Brasil 57072-970 e-mail: [wgv@fapeal.br](mailto:wgv@fapeal.br)

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

<sup>3</sup>CTG/DEQ - UFPE, 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 que melhor representaram o modelo foram 5x15x4 e 8x15x4 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.

**Abstract:** 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. From the results, the architectures chosen for the FCC neural modeling were 5x15x4 and 8x15x4 and with convergence criteria of  $10^{-3}$ . 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.

**Key words:** FCC, process identification, artificial neural networks, MIMO system.

## 1 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 sendo ele 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 (Narendra and Mukhopadhyay, 1997).

Já foram desenvolvidas diversas pesquisas baseadas em RNA: Narendra (1996) 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 et al. (1996) expõem um procedimento de treinamento backpropagation que é aplicado em um reator CSTR. De Souza 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 de processo de fabricação. Santos et al. (2000) reportam a aplicação de uma RNA para identificação e controle de um processo FCC usando dois modelos de processo diferentes: um simplificado “side-by-side” e outro mais complexo. O estudo ficou restrito a um sistema SISO (Single Input and Single Output).

A unidade de FCC é um dos processos mais importantes em refinarias de petróleo devido ao grande volume de produtos processados e alto valor agregado. Um pequeno benefício neste processo é economicamente atraente. Porém, as unidades de FCC apresentam processos fisicamente complexos com dificuldades para operar e controlar. Diversos autores apresentaram estudos de modelagem e/ou controle envolvendo a unidade de FCC. 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 a análise da dinâmica da planta e para testes de um sistema de controle multivariável. Aguilera 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.

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

(2000) descrevem a implementação de uma nova estratégia de otimização não convencional em tempo real aplicada em um conversor FCC. 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. Sarma and Rengaswamy (2000) usaram uma rede de controladores de lógica fuzzy (GS-FLCs), usando padrão sigmoidal (SGS). 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. Uma identificação baseada em redes neurais pode fornecer ao projetista desta unidade um melhor entendimento da dinâmica do processo podendo ainda ser útil como um modelo interno para um Controlador Preditivo.

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). Na sessão 2 é feita uma breve Descrição do Processo. A Metodologia é apresentada na sessão 3, com a Obtenção dos Dados na sessão 3.1.e o Procedimento de Treinamento da Rede na sessão 3.2. Os Resultados e Conclusões 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 recebe como carga as correntes provenientes de várias unidades da refinaria. Como produtos gerados, tem-se: 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 de uma unidade de craqueamento. Devido às condições de temperatura do reator, ocorrem também reações secundárias indesejáveis, como formação de

coque, polimerização e desidrogenação, com conseqüente deposição de coque 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 com injeção de ar, regenerando o catalisador (vide Fig. 1). Desta forma o catalisador é circulado da seção de reação para a seção de regeneração, retornando para a seção de reação (vide Fig. 2).

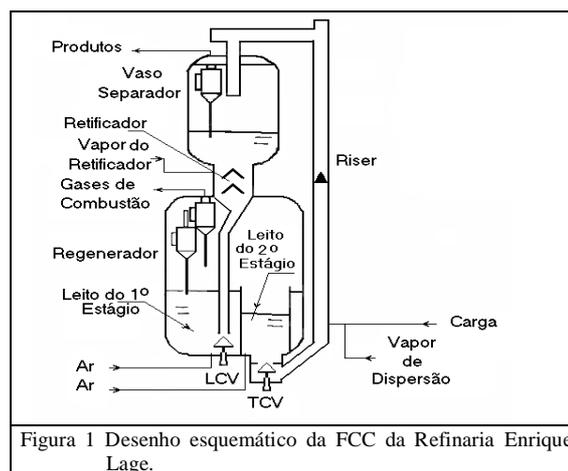


Figura 1 Desenho esquemático da FCC da Refinaria Enrique Lage.

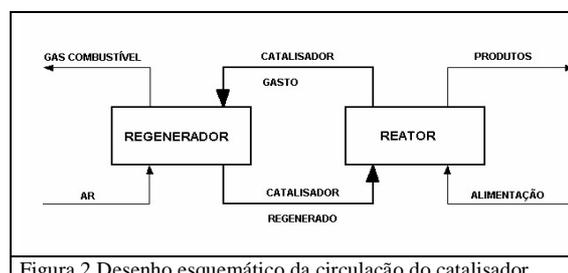


Figura 2 Desenho esquemático da circulação do catalisador

Devido às condições extremamente severas de operação, há necessidade de controle rigoroso de algumas variáveis operacionais (controladas), o que 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 controladas as seguintes variáveis: temperatura de saída do reator, TRX; temperaturas das fases densas do primeiro e segundo estágios de regeneração, TRG1 e TRG2; e conversão do reator, severidade da reação catalítica. 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.

Tabela 1 Variáveis manipuladas, e suas respectivas perturbações impostas.

Variáveis manipuladas	CONJUNTO DE TREINAMENTO E VALIDAÇÃO				CONJUNTO DE TESTE	
	Degrau (%)		Tempo (min.)		Degrau (%)	Tempo (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		

### 3 METODOLOGIA

A técnica de treinamento supervisionado foi usada neste trabalho. Neste procedimento 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 (Baughman and Liu, 1995).

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” (De Souza Jr., 1993; Haykin, 1994).

#### 3.1 Obtenção dos Dados

Um modelo fenomenológico desenvolvido por Moro (1992) foi usado para gerar os dados de processo para treinamento e teste do modelo em rede neural.

Fazendo uso de simulações numéricas baseado neste modelo, primeiramente foi obtido um estado estacionário inicial. Então, vários degraus foram aplicados nas variáveis manipuladas sendo monitoradas as respostas nas variáveis controladas. A tabela acima (Tab. 1) apresenta as variáveis manipuladas, os respectivos degraus impostos e o intervalo de tempo entre eles.

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) (vide Tab. 1).

#### 3.2 Treinamento da RNA

Com os conjuntos de dados obtidos das simulações numéricas, inicia-se o procedimento de aprendizagem. Uma rede multicamada feedforward 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 obtidas do instante de tempo anterior, e na segunda estrutura era formada por quatro variáveis manipuladas e quatro controladas obtidas do instante de tempo anterior. A camada de saída foi formada pelas quatro variáveis controladas, obtidas no instante de tempo atual

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. Hecht-Nielsen, (1989) já havia provado que qualquer função contínua não linear 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 determinada 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. Um número excessivo de padrões de treinamento (mais de 5000 padrões) foi usado inicialmente, porém, a convergência só foi atingida quando este número foi reduzido para valores inferiores a 1500 padrões, dependendo da precisão e do número de nodos na camada escondida. O critério de convergência usado abrangeu de  $10^{-9}$  a  $10^{-3}$  no gradiente da função objetivo. O número de nodos de 1 a 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.

### 4 RESULTADOS E CONCLUSÕES

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.

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 e validação da rede, 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 nos sinais das variáveis controladas.

Com um número reduzido de nodos (1 a 5) e usando como critério de convergência de  $10^{-9}$  a  $10^{-5}$  no gradiente da função objetivo, a convergência não foi atingida e algumas oscilações do processo não puderam ser capturadas em alguns testes o que poderia ser consequência 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  $(10^{-3})$ . O número de padrões também foi reduzido (1000 padrões).

Nos gráficos (Fig. 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 fenomenológico. Foram usados arquitetura 5x15x4 e critério de convergência de  $10^{-3}$  no gradiente da função objetivo. Como pode ser observado, o erro relativo entre modelo e rede praticamente desaparece para as variáveis TRG1 e TRG2. Para severidade da reação catalítica e TRX, os erros relativos foram aproximadamente 0.15% e 0.1%.

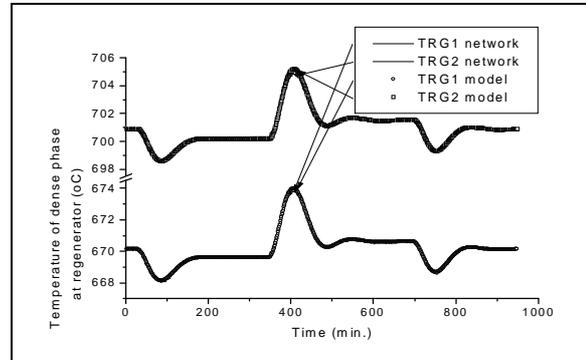


Figura 3 Resposta entre modelo e rede neural para as variáveis TRG1 e TRG2 com 3 degraus na variável CTCV.

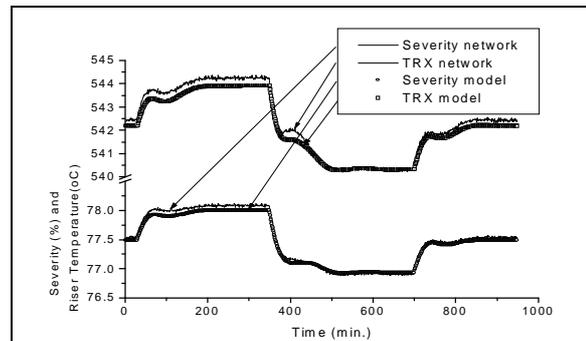
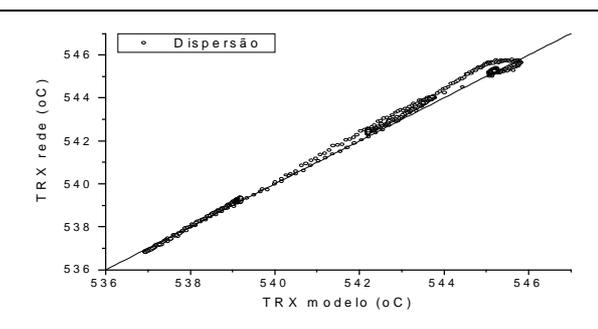
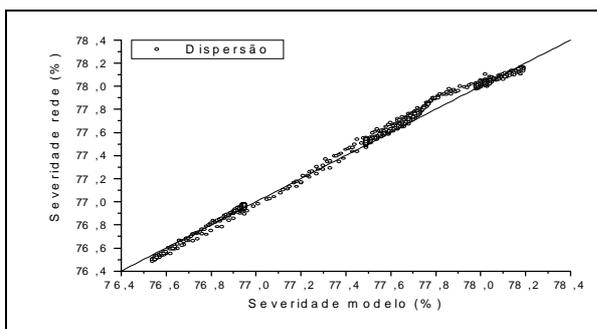
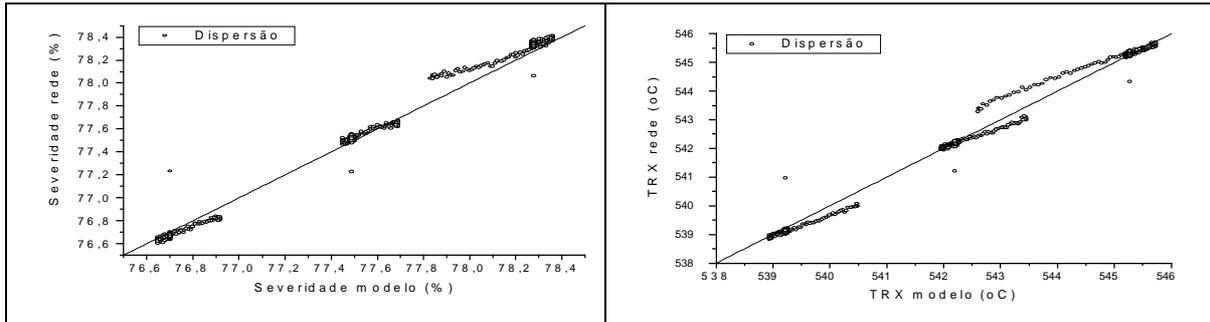


Figura 4 Resposta entre modelo e rede neural para as variáveis Severidade da reação e TRX com 3 degraus na variável CTCV.

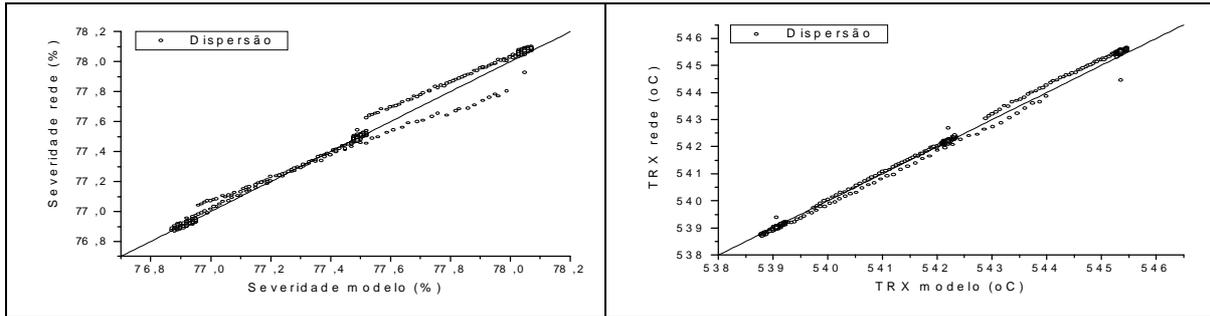
Foram também dados degraus nas variáveis RAI, RTF e TFP obtendo comportamento similar ao anterior. O erro relativo entre modelo em redes neurais e modelo fenomenológico é mostrado em forma de dispersão nos gráficos seguintes (Fig. 5 a 10). Estas figuras mostram a proximidade entre os resultados do modelo em redes neurais e os resultados obtidos por simulação fenomenológica.



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.

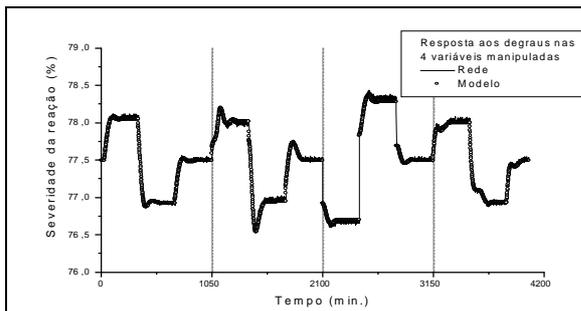
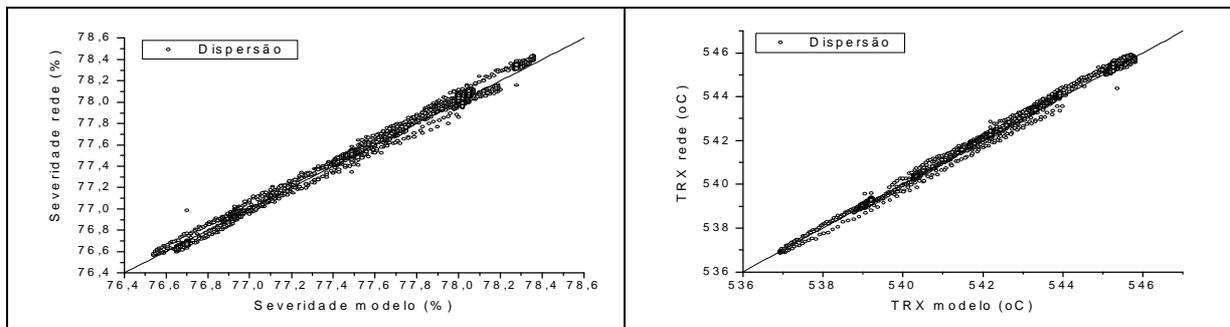


Figura 11 Resposta entre modelo e rede neural para a variável severidade da reação com 12 degraus nas variáveis manipuladas.

Os resultados para a segunda estrutura da rede (arquitetura 8x15x4) com critério de convergência de  $10^{-3}$ , é apresentado no gráfico da Fig. 11 (severidade da reação catalítica). A diferença entre modelo

fenomenológico e rede pode ser melhor observada nas Fig. 12 e 13 seguintes.

Dos resultados obtidos, as arquiteturas escolhidas para modelar a FCC em rede neural foram 5x15x4 e 8x15x4. Em todos os testes realizados o erro relativo entre modelo e rede das variáveis de saída foi inferior a 1%. 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 predições de alta qualidade das variáveis controladas. 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.



Figuras 12 e 13 Resposta da dispersão relativa entre modelo e rede neural para as variáveis controladas severidade da reação e TRX com 12 degraus nas variáveis manipuladas.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

- Narendra, K.S. & Mukhopadhyay, S., 1997, 'Adaptive Control Using Neural Networks and Approximate Models'. *IEEE Transactions on Neural Networks*, 8(3), pp. 475-485.
- Narendra, K.S., 1996, 'Neural Networks for Control: Theory and Practice'. *Proceeding of the IEEE*, vol. 84(10), pp. 1385-1406.
- 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.
- De Souza Jr, M.B. (1993) 'Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos'. Dr. Thesis, COPPE/UFRJ, Brazil.
- 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.
- 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.
- Aguilara, 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.
- 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.
- 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.
- Moro, L.F.L. (1992) 'Desenvolvimento de um controlador preditivo multivariável para um conversor industrial de Craqueamento Catalítico'. MSc. Thesis, USP/SP, Brazil.
- Haykin, S. (1994) 'Neural Networks – A Comprehensive Foundation' Macmillan Publishing Co. NJ, 696p.
- Baughman, D.R. & Liu, Y.A. (1995) 'Neural Networks in Bioprocessing and Chemical Engineering'. Academic Press, Inc. London, 489p.
- Hecht-Nielsen, R. (1989) 'Theory of the Backpropagation Neural Network', *IEEE Int. Conf. On Neural Networks*, I, pp. 593-605.