



2º CONGRESSO BRASILEIRO DE P&D EM PETRÓLEO & GÁS

Modelagem por Redes Neurais de um Processo Industrial de Coqueamento Retardado de Óleos Nacionais Pesados

Sandra Vettorazzi Lopez ¹, Maurício Bezerra de Souza Jr ¹, Donato Alexandre Gomes Aranda ¹,
Enrique Luis Lima ², Mário César Mello Massa de Campos ³

¹ DEQ/EQ/UFRJ, Centro de Tecnologia, Bloco E, Ilha do Fundão, CEP.: 21949-900, Rio de Janeiro, RJ, Brasil, slopez@eq.ufrj.br

² PEQ/COPPE/UFRJ, Centro de Tecnologia, Bloco G, Ilha do Fundão, C. P. 68502, CEP.: 21945-970, Rio de Janeiro, RJ, Brasil.

³ CENPES, PETROBRAS, Cidade Universitária, Quadra 7, Ilha do Fundão, CEP.: 21949-900, Rio de Janeiro, RJ, Brasil.

Resumo – O processo de coqueamento retardado é economicamente interessante, podendo ser empregado em frações residuais de petróleos nacionais pesados para obter produtos mais leves e de maior valor comercial. Poucos trabalhos existem na literatura abordando a modelagem destes processos, que apresentam interações complexas. Neste trabalho, modelos empíricos foram desenvolvidos, empregando dados operacionais da Refinaria REGAP (PETROBRAS) para relacionar a qualidade do coque e rendimento dos produtos do processo de coqueamento retardado (nafta, GLP, gasolina e coque) com variáveis de operação (vazão, pressão, temperatura etc) e de qualidade da carga (densidade, viscosidade e teor de carbono residual). Redes neurais foram adotadas por serem capazes de representar processos complexos e/ou não lineares. O programa Statistica foi empregado no treinamento e validação das redes neurais. Os resultados obtidos mostraram que os modelos exibem capacidade preditiva razoável, conforme indicado pelos critérios estatísticos de análise de resíduos. Análises de sensibilidade foram também procedidas de modo a verificar as variáveis de entrada que mais afetavam as saídas analisadas, permitindo indicar variáveis para o controle do processo. Os modelos obtidos constituem-se em ferramenta básica para o controle global do processo.

Palavras-Chave: refino; análise de sensibilidade; petróleo

Abstract – Delayed coking is an economically interesting process as it can be used to obtain light products, of high added value, from residual fractions of Brazilian heavy petroleum. Very few works are found in the literature about the modeling of these processes, which present complex interactions. In this paper, empiric models were developed using operational data from REGAP Refinery (PETROBRAS). These models relate coke quality and product yields of the delayed coking process (naphtha, LGP, gasoline and coke) with operational variables (flow rates, pressures, temperatures etc.) and characteristics of the feed (density, viscosity and residual carbon content). Neural networks were employed as they are able to represent complex and/or nonlinear processes. The Statistica program was used in the training and validation of the neural networks. The residual statistical analysis of the results show that the models exhibit a reasonable predictive ability. Sensitivity analysis were also carried out in order to identify which input variables affected most the output variables. This sensitivity analysis also allowed the indication of effective manipulated variables for multivariable control. The neural net models obtained are a basic tool for the process plantwide control.

Keywords: refine, sensitivity analysis, petroleum

1. Introdução

O coqueamento retardado é um processo de craqueamento térmico utilizado em refinarias de petróleo, com o objetivo de aumentar a conversão dos resíduos de destilação do petróleo (resíduos de vácuo, resíduos atmosféricos, óleos decantados), transformando-os em produtos mais leves e de maior valor agregado (Ellis e Paul, 1998). A figura 1 mostra um esquema com os produtos obtidos por esse processo.

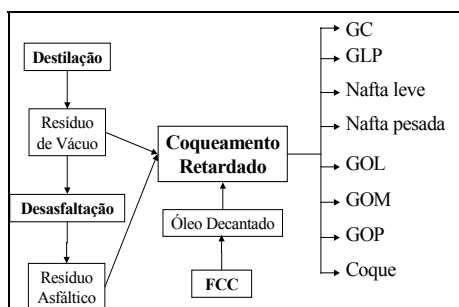


Figura 1. Produtos obtidos pelo processo de coqueamento retardado

O processo de coqueamento é muito importante para óleos pesados, que é o caso brasileiro. Esse processo é altamente rentável e está sendo cada vez mais implantado nas refinarias, sendo uma das próximas a REDUC, no Rio de Janeiro. Entretanto, a modelagem desse processo ainda é muito incipiente, justificando, portanto, sua abordagem.

Neste trabalho procedeu-se a modelagem empírica do processo, através do treinamento e validação de redes neurais, para rendimentos dos diversos produtos (coque, GLP, nafta, etc) empregando dados industriais da refinaria REGAP / PETROBRAS.

Pretende-se com o modelo obtido proceder análises preliminares visando ao controle posterior da unidade completa (*plantwide control*) (Larsson, 2000). Assim, o modelo será usado para auxiliar na análise do nível mais alto para o nível mais baixo (*top-down analysis*) na qual serão selecionadas as variáveis controladas (tendo por base considerações econômicas) e as variáveis manipuladas (tendo por base testes de sensibilidade).

2. Fundamentos

2.1. Descrição do processo de coqueamento

Uma das características deste processo é a geração de um material sólido muito concentrado em carbono chamado coque. O coque pode apresentar três estruturas físicas distintas: shot, esponja e agulha. E a sua estrutura física e suas propriedades químicas é que vão determinar a sua utilização final como combustível; anodos para indústria de alumínio; eletrodos para indústria metalúrgica, dentre outros (Lobo e Ribeiro, 2001).

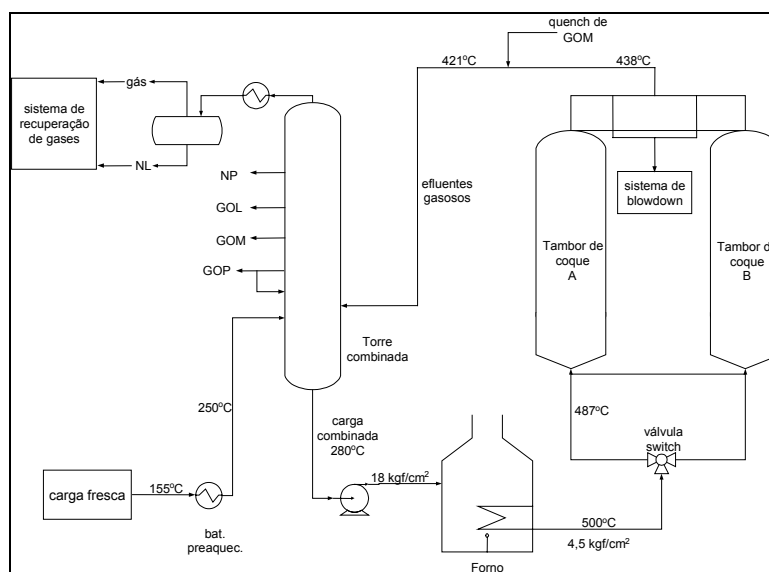


Figura 2. Fluxograma do processo de coqueamento

Fatores como o tipo de carga processada e a temperatura de saída do forno, influenciam as características físicas do coque, tais como, densidade aparente, VCM (teor de matéria volátil), enxofre e metais.

Neste processo, como ilustrado na figura 2, um forno com tubos horizontais é usado para alcançar a temperatura de quebra das moléculas, podendo variar de 485 a 505°C. Com um curto tempo de residência nos tubos do forno, o coqueamento da carga é “retardado” até que alcance os tambores de coqueamento a jusante. Dessa forma, essas unidades operam de forma semi-contínua. O fluxo de alimentação através do forno é contínuo e a corrente é alternada entre dois tambores. Um tambor fica em linha, enquanto o outro está sendo submetido a descoqueificação (Maciel Filho e Sugaya, 2001). O vapor do topo dos tambores de coque flui para uma torre fracionadora, que tem um reservatório no fundo, onde alimentação fresca é combinada com vapores condensados para formar a alimentação do forno.

2.2 Redes Neurais

As redes neurais (NN) artificiais são modelos matemáticos inspirados em sistemas biológicos neurais teorizados, desenvolvidos de modo a imitar os mecanismos de entendimento ou cognição humanos. As NN podem prover uma representação de processos complexos (e/ou mal definidos e/ou não lineares)

Podem ser usadas como modelos em áreas tão diversas como finanças, medicina, engenharia, geologia e física, em problemas de predição, classificação e controle

Tem o objetivo de estimar o valor de uma variável de saída contínua, dadas as variáveis de entrada conhecidas. Uma NN típica é composta por uma densa rede de elementos processadores (neurônios artificiais), não lineares, dispostos em camadas e interconectados por canais unidirecionais chamadas conexões. Um exemplo é mostrado na figura 3.




Figura 3. Modelo básico de uma rede neural artificial de três camadas

A modelagem baseada em redes neurais pode ser mais genérica e economicamente mais vantajosa que aquela baseada em princípios básicos de conservação, uma vez que as redes empregam apenas dados históricos da planta e são, portanto, facilmente “transportadas” de uma planta para outra.

O paradigma mais empregado de redes neurais é o de redes multicamadas do tipo perceptron (MLP), as quais são treinadas por métodos do tipo “backpropagation” modificados. De Souza Jr. (1993) aborda estas redes MLP

3. Modelagem por Redes Neurais

Dados diários de oito meses de operação da refinaria REGAP / PETROBRAS foram coletados. As seguintes variáveis apresentadas na Tabela 1 estavam disponíveis. Foram categorizadas como variáveis de entrada para o modelo as propriedades da carga e variáveis operacionais e como variáveis de saída os rendimentos dos produtos obtidos.

Tabela 1. Variáveis de entrada e variáveis de saída estudadas

Variáveis de entrada	Variáveis de saída
Vazão de carga fresca (ton/dia)	Rendimento de GLP
Temperatura de entrada do tambor (° C)	Rendimento de NL
Temperatura do topo (° C)	Rendimento de NP
Pressão no topo do tambor (kgf/cm ² g)	Rendimento de GOL
Razão de reciclo	Rendimento de GOM
RCC (Resíduo de Carbono Conradson)	Rendimento de GOP
Viscosidade a 98,9 °C	Rendimento de GC
Grau API	Rendimento de coque
Densidade (20/4)	VCM (Volatile Carbon Matter)

O número de padrões disponíveis para o treinamento e seleção das redes neurais foi de 242. Este número, embora correspondendo a vários dias de operação, ainda pode ser considerado pequeno, uma vez que as redes neurais apresentam um número de parâmetros elevado, o que pode produzir problemas de sobreajuste. Assim, de modo a se ter um número de parâmetros menor, algumas variáveis de entrada não foram apresentadas às redes. Por conseguinte, dentre as variáveis relacionadas às características do óleo, apenas a densidade em graus API e o RCC foram usados.

Foram consideradas como variáveis controladas, os rendimentos de GLP, nafta leve, gás combustível e coque.

Para os produtos de topo da fracionadora do processo de coqueamento retardado (GLP; nafta leve e gás combustível) foram treinadas redes MLP (*multilayer perceptron*) com três saídas (Figuras 4 a 6). Metade dos dados foi aleatoriamente escolhida para treinar as redes e metade para validar (ou “selecionar”) as mesmas. O STATISTICA foi empregado para treinar 50 redes, das quais a que produziu melhor resultado exibiu 13 neurônios na camada escondida.

As Figuras 4 a 6 mostram a boa correlação obtida entre os valores observados (experimentais) e os preditos pela rede. Nas figuras, os valores usados para treinamento estão mostrados na cor azul e para seleção, na cor vermelha.

O STATISTICA calcula a razão entre desvios-padrão (“SD RATIO”) expressa pelo quociente do desvio-padrão dos erros do modelo pelo desvio-padrão dos dados. Quanto mais próximo de zero for este parâmetro melhor será o ajuste do modelo. A Tabela 2 apresenta os valores obtidos para a SD RATIO, juntamente com o coeficiente de correlação para a regressão entre os valores preditos e os observados.

Tabela 2. Valores obtidos para a SD RATIO e sua correlação

Variável	SD RATIO	Correlação
Rendimento de GLP	0,64	0,77
Rendimento de NL	0,73	0,68
Rendimento de GC	0,45	0,90




Figura 4 . Rendimento de GLP predito *versus* o observado




Figura 5. Rendimento de Nafta leve predito *versus* o observado




Figura 6. Rendimento de Gás Combustível predito *versus* o observado

A análise dos resultados demonstra um desempenho apenas satisfatório das redes, o que pode ser atribuído à ainda pequena quantidade de dados disponível, o que deixa a rede “sobrecarregada”. Mais ainda, percebe-se que os dados não estão uniformemente distribuídos em toda a região operacional, mas concentram-se em regiões específicas.

O modelo de redes neurais pode ser usado para análise de sensibilidade das variáveis de saída frente às variáveis de entrada. Para tanto, o STATISTICA calcula o erro na saída da rede (em relação aos valores alvos) quando uma dada variável de entrada é substituída pela sua média. A maior magnitude deste erro dá a importância da variável. A Tabela 3 abaixo dá o “ranking” obtido.

Tabela 3. Resultado da análise de sensibilidade para o total das correntes de GLP, Nafta leve e Gás Combustível

Variável	Razão de reciclo	Vazão de carga fresca	Pressão no topo do tambor	RCC	API	Temperatura de entrada do tambor
Ranking	1	2	3	4	5	6

As duas variáveis mais importantes podem ser interpretadas do ponto de vista de controle. A primeira, razão de reciclo, pode ser escolhida como variável manipulada para controlar os rendimentos dos produtos mais leves. A segunda, vazão de carga fresca, também pode ser usada como variável manipulada. Se não for possível usar a vazão de carga fresca como variável manipulada, percebe-se que a mesma se constitui em um importante distúrbio para o sistema de controle. A variável temperatura no topo foi excluída no STATISTICA automaticamente por não contribuir com a diminuição do erro da rede.

Para estimar o rendimento em coque foram treinadas redes MLP (multilayer perceptron) com uma única saída (Figura 7). Metade dos dados foi aleatoriamente selecionada para treinar as redes e metade para validar (ou “selecionar”) as mesmas.




Figura 7. Rendimento de Coque predito *versus* o observado

O STATISTICA foi empregado para treinar 50 redes, das quais a que produziu melhor resultado exibiu 6 neurônios na camada escondida. A rede tem agora apenas 49 parâmetros contra 242 padrões de treinamento, não podendo ser considerada uma rede sobrecarregada.

O “SD RATIO” e a correlação foram, respectivamente, 0,54 e 0,85 (dados para treinamento) e 0,703 e 0,714 (dados para seleção). A Figura 7 exibe os valores preditos pelo modelo contra os valores observados. Percebe-se novamente que os dados estão muito concentrados em uma dada região operacional.

A análise de sensibilidade fornece o “ranking” apresentado na Tabela 4.

Tabela 4. Resultado da análise de sensibilidade para o Coque

	Vazão de carga fresca	RCC	API	Pressão no topo do tambor	Temperatura de entrada do tambor	Temperatura no topo	Razão de reciclo
Ranking	1	2	3	4	5	6	7

A análise da tabela mostra que a vazão de carga fresca é a variável mais importante, seguida de características da carga (RCC e grau API, Segunda e terceira, respectivamente). Estas variáveis podem ser todas consideradas distúrbios para o sistema de controle. Percebe-se que agora a razão de refluxo tem pouca influência. Logo, a pressão no topo do tambor aparece como a variável manipulada de maior influência no rendimento de coque.

4. Conclusões

Um levantamento de dados reais de uma unidade de coqueamento retardado foi procedido. Em seguida, tentou-se desenvolver modelos empíricos baseados em redes neurais para os produtos mais leves e o resíduo. Para o momento, os produtos de retirada lateral da coluna (gasóleos) não foram modelados.

O modelo para os produtos mais leves resultou “sobrecarregado”, mas permitiu observar que a razão de reciclo exerce importante efeito sobre seus rendimentos, indicando-a como variável manipulada no sistema de controle.

O modelo para o coque apresenta uma relação adequada de número de padrões versus número de parâmetros e uma capacidade preditiva razoável. Percebeu-se que a razão de reciclo exerce pouca influência no rendimento de coque, sendo a pressão do tambor uma melhor variável manipulada para atuar sobre este rendimento.

Pretende-se na continuação deste trabalho levantar mais dados operacionais e em faixas mais amplas de operação.

7. Agradecimentos

A todo o apoio financeiro da Agência Nacional do Petróleo (ANP) no programa PRH13 (Processamento, Gestão e Meio Ambiente na Indústria do Petróleo e Gás Natural), aos dados e informações cedidos pelo CENPES/PETROBRAS e à Escola de Química/UFRJ.

8. Referências

- DE SOUZA JR., M. B., *Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos*, Tese de Doutorado, PEQ/COPPE/UFRJ, 1993.
- ELLIS, P. J., PAUL, C. A. *Tutorial: Delayed Coking Fundamentals*, Prepared for presentation at the AIChE Spring National Meeting, New Orleans, LA, p. 1-20, 1998.
- LARSSON, T. (2000). *Studies on Plantwide Control*, Tese de Doutorado, Norwegian University of Science and Technology – Department of Chemical Engineering.
- LOBO, L. F. L. F., RIBEIRO, R. A. R. *Coqueamento Retardado: um processo atraente para recuperação de derivados leves a partir de frações pesadas de petróleo*. Projeto final de curso ANP, EQ/UFRJ, 2001.
- MACIEL FILHO, R., SUGAYA, M.F. A computer aided tool for heavy oil thermal cracking process simulation, *Comp. & Chem. Eng.* 25, p. 683 - 692, 2001