

MODELAGEM EMPÍRICA DE UM SISTEMA DE DESPARAFINAÇÃO DE ÓLEO LUBRIFICANTE USANDO REDES NEURAIS ARTIFICIAIS

Cristiano Hora de Oliveira Fontes¹, Ana Cláudia Gondim de Medeiros¹,
Marcone Lopes Silva¹, Sérgio Bello Neves¹, Luciene Santos de Carvalho¹,
Paulo Roberto Britto Guimarães¹, Nilza Maria Querino Santos²,
Magnus Pereira¹ e Regina Ferreira Vianna¹

¹ Universidade Salvador – Unifacs, Departamento de Engenharia e Arquitetura.
Av. Cardeal da Silva, 132 – Federação, 40.220-141, Salvador-BA, Brasil, paulorbg@unifacs.br
² Petróleo Brasileiro S. A. – PETROBRAS, nilzaq@petrobras.com.br

Resumo – A Unidade de Desparafinação a MBIK (metil-isobutil cetona), localizada na Refinaria Landulpho Alves – RLAM (Bahia, Brasil), possui dois modos de operação: o de desparafinação e o de desoleificação. O primeiro caso compreende a separação óleo-parafina e a geração de uma corrente de parafina com um teor de óleo de 2 a 5%. A desoleificação, por sua vez, consiste no reprocessamento da corrente de parafina para reduzir o seu teor de óleo. Ambos os modos operacionais contemplam dois estágios de filtração (primário e secundário) que utilizam filtros rotativos em paralelo. O objetivo deste trabalho compreende o desenvolvimento de modelos empíricos para a predição de variáveis de processo relacionadas aos dois modos operacionais citados, viabilizando a estimativa, em linha, destas variáveis e o efetivo controle do processo de filtração. Mais especificamente, este artigo apresenta a identificação de um modelo empírico para a predição do teor de óleo na corrente de parafina a jusante dos filtros primários, considerando-se a carga de Destilado Neutro Leve (DNL). O modelo desenvolvido possui uma estrutura baseada em Redes Neurais Artificiais com uma topologia sem retroalimentação de sinais e foram avaliadas arquiteturas com uma e duas camadas intermediárias.

Palavras-Chave: redes neurais artificiais, modelagem empírica, óleo lubrificante

Abstract – The MIBK (m-i-b-ketone) dewaxing unit, located at the Landulpho Alves refinery, allows two different operating modes: 1) dewaxing; and 2) oil removal. The former is comprised of an oil-wax separation process, which generates a wax stream with 2 – 5% oil. The latter involves the reprocessing of the wax stream to reduce its oil content. Both involve a two-stage filtration process (primary and secondary) with rotative filters. The general aim of this research is to develop empirical models to predict variables, for both unit-operating modes, to be used in control algorithms, since many data are not available during normal plant operation and therefore need to be estimated. Studies have suggested that the oil content is an essential variable to develop reliable empirical models and this work is concerned with the development of an empirical model for the prediction of the oil content in the wax stream leaving the primary filters. The model is based on a feed forward Artificial Neural Network (ANN) and tests with one and two hidden layers indicate very good agreement between experimental and predicted values.

Keywords: artificial neural networks, empirical modeling, lubricant oil

1. Introdução

A Unidade de desparafinação consiste essencialmente em um processo de separação de óleo-parafina e envolve dois estágios de filtração (primário e secundário) que utilizam filtros rotativos, tendo-se também a adição de MIBK (metil-isobutil cetona) como solvente. A corrente de parafina na descarga dos filtros secundários possui um teor de óleo de 2 a 5 % e é direcionada, junto com a corrente de óleo, para a seção de recuperação de solvente. A Figura 1 apresenta esquematicamente a seção de filtração da Unidade de desparafinação a MIBK.

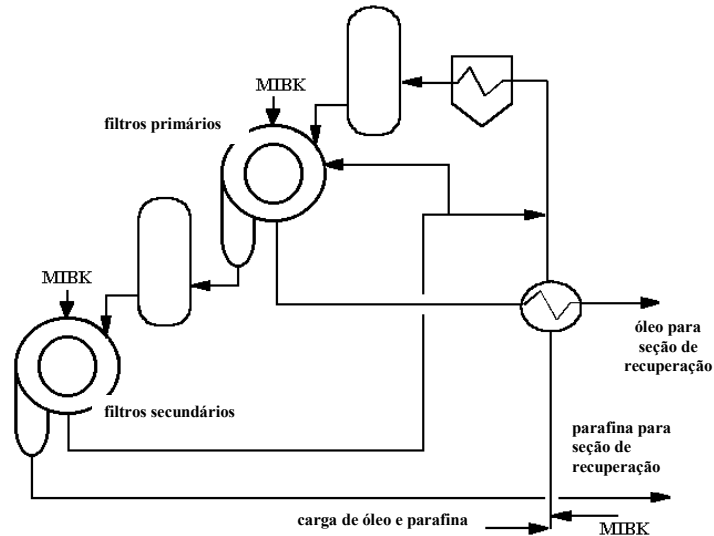


Figura 1. Processo de desparafinação a MIBK.

Considerando-se o longo tempo de análise despendido na medição do teor de óleo na parafina e a importância desta variável no efetivo controle do processo de filtração, o desenvolvimento de analisadores virtuais representa uma alternativa potencial para a estimativa, em linha, do teor de óleo na corrente de parafina.

Este trabalho apresenta a metodologia e os resultados referentes ao desenvolvimento de um modelo empírico para a predição do teor de óleo na corrente de parafina a jusante dos filtros primários. Os resultados apresentados se referem especificamente ao Destilado Neutro Leve (DNL) que compreende um dos três tipos de carga processados na Unidade de desparafinação. O modelo possui uma estrutura baseada em Redes Neurais Artificiais (RNA) com topologia “feedforward” e foram avaliadas situações com uma e duas camadas intermediárias. Redes Neurais Artificiais representam uma ferramenta potencial na determinação de relações funcionais entre múltiplas variáveis (identificação), oferecendo a possibilidade de modelagem não linear de processos (Doherty et al., 1997, Su and McAvoy, 1997). O vasto campo de aplicações das Redes Neurais Artificiais inclui também a obtenção de estimadores de propriedades do óleo cru, a exemplo do coeficiente de compressibilidade isotérmico e da pressão do ponto de bolha (Gharbi e Eisharkawy, 1999, Gharbi, 1997, Gharbi et al., 1999).

O modelo empírico foi desenvolvido usando dados de operação normal do processo que, devido à sua variabilidade intrínseca, dispensou a necessidade de realização de um experimento de identificação com a inserção de perturbações pré-estabelecidas nas variáveis de entrada. Além disso, as amostras de parafina foram coletadas na descarga de um dos filtros primários não tendo sido utilizados resultados de análise de rotina que estão relacionados à corrente de descarga da Unidade. Este procedimento elimina a necessidade de estimativa de um tempo morto referente ao transporte da corrente de parafina da seção de filtração até a descarga da seção de recuperação de solvente. A inclusão de tempo morto no trabalho de identificação representaria uma fonte de erro adicional devido ao nível de incerteza e variabilidade associados a este parâmetro, a exemplo do que ocorre em sistemas de polimerização (Su e McAvoy, 1997).

2. Modelagem Empírica: Procedimento

Um estudo detalhado da etapa de filtração/preparação da carga conduziu a uma definição das variáveis de entrada que influenciam o teor de óleo na parafina. Neste sentido, considerando-se um filtro primário, as seguintes variáveis foram estabelecidas como entradas para o modelo empírico:

- Vazão de carga;
- Temperatura de carga (óleo e parafina);
- Temperatura de alimentação do solvente (MIBK);
- Vazão de alimentação do solvente;
- Variação de pressão do filtro.

Uma análise do comportamento das variáveis de entrada evidenciou a existência de uma variabilidade intrínseca, sugerindo a possibilidade de coleta de dados durante operação normal do processo. Esta estratégia exclui a necessidade de um experimento de identificação que contemplasse a aplicação de perturbações programadas sobre o processo. A Figura 2 ressalta o comportamento transitório da seção primária de filtração, destacando-se os perfis das temperaturas de alimentação da carga e do solvente.




Figura 2. Valores reais de processo. Temperatura de alimentação da carga (óleo e parafina) e temperatura de alimentação de solvente (MBIK).

Na tentativa de obtenção de um modelo satisfatório no tocante a generalização, parcimônia e desempenho, foi adotada uma estratégia de identificação onde a seleção do número de neurônios intermediários foi determinada através de validação cruzada (Doherty et al., 1997, Pollard et al., 1992, Nikravesh et al., 1996). O treinamento e a validação cruzada foram efetuados simultaneamente, tendo-se a determinação do número de épocas condicionado à obtenção de erro mínimo na amostra de teste.

A rede compreendeu uma topologia “feedforward” (sem a retroalimentação de sinais), sendo realizados testes com uma e duas camadas intermediárias com função de ativação tangente hiperbólica (Hunt et al., 1992). Os dados foram normalizados no intervalo $[-1;1]$ e um total de 100 amostras de parafina foram coletadas para a análise de teor de óleo. As amostras de treinamento (73 dados) e de teste (27 dados) foram aleatoriamente selecionadas assegurando-se, entretanto, a inserção dos dados de teste no intervalo dos dados de treinamento. O algoritmo de Levenberg-Marquardt (Haykin, 1994) foi utilizado para o treinamento da rede e determinação dos parâmetros do modelo (pesos sinápticos) e, sendo um dos métodos clássicos de otimização, o gradiente, a cada iteração, é calculado a partir do erro quadrado médio de cada época.

3. Resultados

A Tabela 1 compara os resultados obtidos com uma e duas camadas intermediárias, variando-se a quantidade de neurônios de 3 a 10, em cada camada. No caso de duas camadas intermediárias, estão apresentadas as combinações de neurônios que produziram menores valores de erro.

Tabela 1. Resultados com arquitetura de uma e duas camadas intermediárias

Uma camada intermediária			Duas camadas intermediárias		
Neurônios	Erro médio relativo (%)		Neurônios (1ª e 2ª camadas)	Erro médio relativo (%)	
	Treinamento	Teste		Treinamento	Teste
3	13,8	11,5	3-9	9,8	10,7
4	11,5	14,9	4-8	9,8	10,6
5	12,6	11,3	5-10	11,4	11,5
6	14,7	12,3	6-6	7,7	11,7
7	10,3	14,9	7-3	13,3	11,6
8	17,0	16,7	8-4	10,4	10,3
9	10,7	13,2	9-12	11,9	10,6
10	9,9	13,2	10-5	8,6	12,0

Os valores obtidos para o coeficiente de correlação, em cada teste de simulação, também atestam melhor desempenho do modelo empírico a partir da inclusão de uma segunda camada intermediária. Desta forma, foi selecionada a rede com 4 e 8 neurônios na primeira e segunda camadas, respectivamente, tendo-se, neste caso, um coeficiente de correlação de 0,81 para a amostra de treinamento e 0,68 para a amostra de teste. Os resultados de simulação estão apresentados na Figura 3, destacando-se o gráfico de paridade com dados de treinamento e de teste, e a comparação direta entre os valores reais e preditos para amostra de teste.




Figura 3. Valores reais e preditos para o teor de óleo na parafina. (a) Gráfico de Paridade e (b) dados reais e simulados para a amostra de teste.

Os valores reais e preditos para o teor de óleo, referentes à amostra de teste ou validação (Figura 3b), estão discriminados na Tabela 2, juntamente com os valores pontuais de erro relativo. Vale ressaltar que o método analítico atualmente utilizado para a obtenção de teor de óleo compreende um erro em torno de 10 %.

Tabela 2. Valores reais e preditos (teor de óleo) para a amostra de teste

Teor de óleo predito (%)	Teor de óleo real (%)	Erro relativo (%)
13,4	14,9	-10,4
10,6	12,8	-17,3
9,7	9,8	-1,6
10,4	10,0	4,1
12,5	11,8	6,5
7,2	7,8	-7,7
12,8	11,6	10,3
10,1	7,4	36,3
10,0	8,6	16,4
10,8	11,1	-2,1
12,0	11,1	8,1
11,6	12,1	-3,6
12,8	11,8	9,2
13,1	13,0	1,2
11,2	10,2	9,8
11,0	10,4	6,2
8,9	10,5	-16,0
9,6	11,1	-13,3
10,5	11,9	-11,7
10,6	12,9	-18,1
11,0	12,1	-8,8
11,3	9,0	25,4
9,5	10,6	-10,3
9,2	8,1	13,8
10,5	10,9	-3,5
10,5	11,4	-8,1
14,1	13,2	7,5

4. Conclusões

Os resultados apresentados ilustram a potencialidade das Redes Neurais Artificiais na modelagem de sistemas químicos evidenciando sua capacidade de generalização, mesmo na presença de dificuldades provenientes da qualidade dos dados.

Embora o modelo empírico identificado tenha apresentado um bom desempenho qualitativo, a característica intrínseca associada à abordagem com redes neurais artificiais e os resultados obtidos sugerem a necessidade de obtenção de uma quantidade de dados superior ao tamanho da amostra disponível (100 pontos). Esta exigência será decisiva para a obtenção de modelos com melhor desempenho. Por outro lado, a dificuldade de aquisição de dados em grande quantidade também estabelece a possibilidade de adoção de estratégias de identificação alternativas (Ljung L., 1987 e Embiruçu M., 1998) onde o tamanho da amostra disponível seja aproveitado de forma otimizada tanto para o treinamento como para a validação cruzada do modelo.

A dificuldade de medição, em linha, de variáveis relacionadas à seção de filtração (teor de óleo na parafina e ponto de fluidez do óleo) estabelece um desafio adicional para o efetivo controle do processo. Neste sentido, os modelos empíricos tornam-se ferramentas potenciais propiciando a predição de valores para o teor de óleo e ponto de fluidez do óleo, e a conseqüente inclusão destas variáveis em um algoritmo de controle preditivo multivariável (Qin and Badwell, 1997).

5. Agradecimentos

Os autores agradecem o suporte financeiro fornecido pela Financiadora de Estudos e Projetos (FINEP), através do Fundo Setorial CTPetro, pela PETROBRAS, através da Refinaria Landulpho Alves (RLAM), e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

6. Referências

- DOHERTY S. K., GOMM J. B. e WILLIAMS D., “Experiment Design Considerations for Non-Linear System Identification Using Neural Networks”, *Computers Chem. Engng*, vol. 21, no 3, 327-346, (1997).
- EMBIRUÇU M., “Modelagem, Estimação e Controle em Reatores Industriais de Polimerização de Eteno com Catálise Ziegler-Natta Solúvel”, Tese D. Sc. PEQ/COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1998.
- GHARBI R. B. C., “Estimating the Isothermal Compressibility Coefficient of Undersaturated Model East Crudes Using Neural Networks”, *Energy & Fuels*, 11, 372-378, 1997.
- GHARBI R. B. C. e EISHARKAWY A. M., “Neural Network Model for Estimating the PVT Properties of Middle East Crude Oils”, *SPE Reservoir Eval. & Eng.* 2(3), 1999.
- GHARBI R. B. C., EISHARKAWY A. M. e KARKOUB M., “Universal Neural-Network-Based Model for Estimating the PVT Properties of Crude Oil Systems”, *Energy & Fuels*, 13, 454-458, 1999.
- HAYKIN S., “Neural Networks; A Comprehensive Foundation”, Prentice-Hall, Inc., 1994.
- HUNT K. J., SABRBARO D., ZBIKOWSKI R. e GAWTHROP P. J., “Neural Networks for Control Systems – A Survey”, *Automatica*, vol. 28, no 6, 1083-1112, 1992.
- Ljung L., “System Identification: Theory for the User”, Prentice-Hall, Englewood Cliffs, New Jersey, E.U.A., 1987.
- NIKRAVESH M., FARELL A. e STANFORD T. G., “Model Identification of Nonlinear Time Variant Processes via Artificial Neural Network”, *Computers Chem. Engng*, vol. 20, no 11, 1277-1290, 1996.
- POLLARD J. F., BROUSSARD M. R., GARRISON D. B. e SAN K. Y., “Process Identification Using Neural Networks”, *Computers Chem. Engng*, vol. 16, no 4, 253-270, 1992.
- QIN S. J. e BADWELL T. A., “An Overview of Industrial Model Predictive Control Technology”, *AIChE Symp. Ser.*, 93, 232-256, 1997.
- SU H. T. e MCAVOY T. J., em HENSON M. SEBORG D., “Nonlinear Process Control”, Prentice-Hall, Inc., (1997).