

Predição da Incrustação em um Trocador de Calor Baseada em Redes Neurais Artificiais

Victor Leonardo Cavalcante Melo da Silva, Jorge Dantas de Melo, Adrião Duarte Dória Neto
Departamento de Engenharia de Computação e Automação
Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil

Márcia Maria Lima Duarte
Departamento de Engenharia Química
Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil

Abstract—The tendency to fouling is a common problem that affects an oil refinery's processing units. Residues naturally present on the oil or chemical products added during its transport deposit and foul tubes and internal surfaces of equipments. A fouled heat exchanger loses its capacity to adequately heat the oil, needing to be shut down periodically for cleaning. Previous knowledge of the best period to shut down the exchanger may improve the energetic and production efficiency of the plant. In this work we develop a system to predict the fouling on a heat exchanger from a real refinery, based on data collected in a partnership with Petrobras. Recurrent Neural Networks are used to predict the heat exchanger's flow in future time. This variable is the main indicator of fouling, because its value decreases gradually as the deposits in the tubes reduce their diameter. The prediction could be used to help plan the maintenances, providing previous information about the fouling evolution.

Keywords—artificial neural networks, prediction, system identification, fouling, heat exchanger.

Resumo—A tendência à formação de incrustação é um problema comum que afeta unidades de refino de petróleo. Materiais que estão naturalmente presentes no petróleo ou produtos químicos adicionados durante o seu transporte se depositam e sujam tubos e paredes internas de equipamentos. Um trocador de calor, quando incrustado, perde sua capacidade de aquecer adequadamente o petróleo, precisando, periodicamente, ser retirado de operação, para que possa ser realizada uma limpeza. Informações prévias do melhor período para realizar as paradas podem melhorar a eficiência energética e de produção da planta. Esse trabalho desenvolveu um sistema de predição da incrustação em um trocador de calor de uma refinaria real, com base em dados coletados em parceria com a Petrobras. Foram utilizadas redes neurais recorrentes que preveem a vazão no trocador em instantes futuros. Essa variável é o principal indicador da incrustação, pois seu valor diminui gradualmente à medida que os depósitos nas paredes dos tubos reduzem seu diâmetro. A predição pode ser usada para auxiliar no planejamento das manutenções, fornecendo informações prévias da evolução da incrustação.

Palavras-chave—redes neurais artificiais, predição, identificação de sistemas, incrustação, trocador de calor

I. INTRODUÇÃO

O Rio Grande do Norte é um dos maiores produtores de petróleo em terra do Brasil e boa parte desse petróleo é refinada localmente, na Refinaria Potiguar Clara Camarão (RPCC), localizada no município de Guamaré. O petróleo produzido no estado não está isento de um problema que ocorre em qualquer refinaria: tendência à formação de incrustação, principalmente nas correntes dos derivados produzidos na coluna de destilação. Esse problema consiste na deposição de produtos químicos, sais, restos orgânicos e sujeiras em geral, o que diminui gradativamente a eficiência do processo de refino, até um ponto em que é necessário retirar equipamentos incrustados de operação para realizar a sua limpeza.

No processo de refino do petróleo, a quantidade de energia envolvida é muito grande. Com o propósito de reduzir o consumo energético da planta, o óleo cru que alimenta uma unidade de destilação atmosférica é submetido a um processo de preaquecimento, passando por trocadores de calor antes de entrar na torre. Um trocador de calor é um equipamento onde ocorre uma troca térmica entre dois fluidos, normalmente sem haver um contato físico entre eles. Há diversos tipos construtivos, dentre os quais um dos mais usados industrialmente é o de feixe tubular, constituído por um conjunto de tubos envoltos por um casco. Um dos fluidos circula no interior dos tubos e o outro fluido escoia no lado externo. A formação da incrustação em trocadores de calor representa uma resistência à transferência de calor e, com o passar do tempo, reduz o desempenho térmico destes equipamentos. A capacidade de monitorar a incrustação dos trocadores e de suas redes é de fundamental importância para o sucesso econômico de uma refinaria. Na Fig. 1 pode ser visto o conjunto de tubos de um trocador de calor bastante atacado pela incrustação.

Os danos causados pela incrustação nos trocadores são significativos. Pesquisas de [1] indicam uma perda de até 0,3% da produção de um país. Eles apontam para a importância de um agendamento adequado das paradas para limpeza. Essa é a maior motivação para essa área de pesquisa, que atualmente está dividida em três frentes: monitoramento, predição e contramedidas. O monitoramento refere-se a técnicas para detectar e avaliar a incrustação. A predição, estudada nesse trabalho, refere-se a métodos para fornecer informações prévias acerca da evolução do processo de incrustação. As

contramedidas referem-se a métodos físico-químicos para evitar a formação da incrustação ou para removê-la.

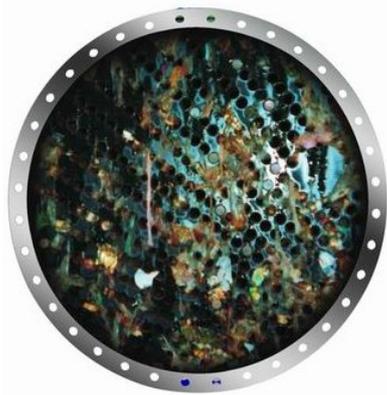


Fig. 1. *Incrustação em tubos de um trocador de calor*

Na produção de querosene de aviação (QAV) da Refinaria Potiguar Clara Camarão, a incrustação ocorre em particular nos trocadores de calor da bateria de preaquecimento da coluna de destilação. Esses trocadores tem a função de preaquecer o óleo cru que vem dos campos de produção, aproveitando a energia térmica do QAV que sai quente da coluna. Ao analisar o material incrustado, os especialistas da planta verificaram que a sua origem se deve principalmente a produtos químicos sequestrantes de H₂S. Esses produtos são dosados no tratamento do petróleo desde os poços produtores até as estações de tratamento, e tem a função de evitar a corrosão dos dutos. Essas substâncias se depositam nos tubos internos do trocador de calor, provavelmente por possuírem um ponto de fragmentação similar ao do QAV, fluido circulante nesses tubos. Filtros convencionais e dessalgadoras são usados para tratar o óleo antes do processo de refino, mas não é possível remover todos os produtos causadores da incrustação.

Em visita técnica à refinaria, foram constatados os efeitos da incrustação. Os operadores da planta observam que, à medida que o trocador sofre mais incrustação, é necessário aumentar a energia no forno da coluna de destilação, pois o petróleo não entra aquecido o suficiente pelo trocador. Além disso, a redução da carga térmica retirada da coluna eleva a sua temperatura de topo, prejudicando a qualidade dos destilados, principalmente do diesel. Para manter a especificação dos produtos é necessário reduzir o rendimento. Os operadores apontaram uma perda de rendimento de até 3% quando a incrustação atinge um nível crítico. Para evitar maiores perdas de produção, o equipamento precisa ser retirado de operação para que seja realizada uma limpeza.

II. PROPOSTA DO TRABALHO

De acordo com [2], a formação da incrustação é um processo químico e físico complicado, que é influenciado por muitos fatores, de forma que a pesquisa inicial na predição de incrustação, baseada no entendimento exato dos mecanismos de formação, não é ideal. Nos anos recentes, a inteligência artificial foi largamente aplicada em processos industriais, e alcançou resultados muito bons. Redes neurais têm grande capacidade de aprendizado, processamento paralelo e resolução de problemas multidisciplinares, de forma que a predição

indireta com redes neurais é o novo caminho que pode ser tomado.

Nesse trabalho foi desenvolvido um sistema baseado em redes neurais artificiais capaz de prever o nível da incrustação no trocador de calor. Essa predição tem o propósito de permitir um melhor planejamento das paradas, pois com ela, os operadores podem saber a priori se a incrustação terá ou não atingido um nível inaceitável em um intervalo de tempo arbitrário. O melhor planejamento das paradas por consequência melhorará a eficiência geral do processo. Além disso, os operadores poderiam alimentar o sistema com condições de operação hipotéticas, permitindo analisar em quais casos a incrustação ocorre mais ou menos rapidamente.

O sistema consiste basicamente de uma rede neural artificial com arquitetura recorrente treinada para modelar o trocador de calor, aprendendo como a incrustação afeta o seu funcionamento e ser capaz de prever esse efeito. A rede neural artificial recebe em sua entrada uma estimativa de quais serão as condições de operação do trocador mais uma indicação atual da incrustação. Com base nesses dados, o sistema deverá ser capaz de prever a evolução da incrustação nas próximas horas e dias, supondo que as condições de operação mantenham-se similares.

No caso estudado, o maior indicador da incrustação é a vazão de QAV através do trocador de calor. O seu valor possui significado natural para os operadores, que inferem o nível da incrustação a partir do valor desta vazão. Portanto, essa é a variável prevista pelo sistema de predição.

III. METODOLOGIA

A. Coleta e Análise de Dados

Para o desenvolvimento do presente trabalho, foram coletadas em parceria com a Petrobras 6 variáveis referentes ao trocador de calor da RPCC mais prejudicado pela incrustação: vazão do fluido quente (QAV), vazão do fluido frio (petróleo), temperaturas de entrada e de saída do fluido quente e temperaturas de entrada e de saída do fluido frio. Os dados foram coletados diretamente do banco de dados do sistema de supervisão da refinaria. Foram referentes a um tempo de 5 meses com um período de amostragem de 1 hora, nos quais foram identificados 10 ciclos de operação do trocador, ou seja, 10 períodos de operação contínua do equipamento, entre as paradas para manutenção. A aplicação de interpolações lineares foi realizada para eliminar valores espúrios (outliers) e tratar eventuais problemas como congelamento ou perda de dados.

A presença da incrustação pode ser claramente constatada através da análise dos dados. A vazão de QAV durante um dos ciclos de operação do trocador de calor pode ser vista na Fig. 2.

A incrustação reduz o diâmetro dos tubos de circulação do QAV, causando a diminuição da vazão ao longo do tempo. A queda de vazão é o maior indicador da incrustação. Em média, o trocador é retirado de operação para limpeza quando a vazão cai abaixo de 20 m³/h. Após a limpeza, a vazão retoma em média o valor de 40 m³/h.

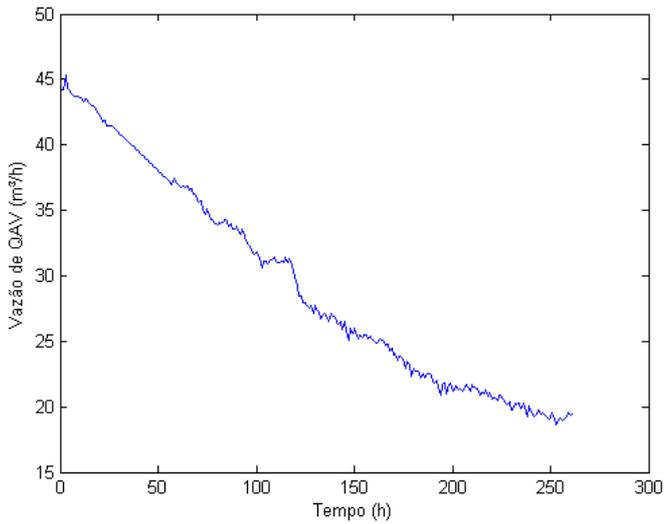


Fig. 2. Vazão durante um ciclo de operação

B. Definição do Modelo

Redes neurais artificiais recorrentes foram definidas para modelar matematicamente o trocador de calor em questão, segundo o modelo NARX (Nonlinear AutoRegressive eXogenous), no qual as saídas dependem dos valores das entradas e das saídas no instante atual e nos instantes anteriores, conforme (1):

$$y(t+1) = f[x(t), x(t-1), \dots, x(t-n_p), y(t), y(t-1), \dots, y(t-n_q)] \quad (1)$$

Em que y é a saída da rede neural, x é o seu vetor de entrada, n_p é o número de regressores de entrada e n_q é o número de regressores de saída. Uma rede neural do tipo perceptron de múltiplas camadas que implementa essa estrutura pode ser vista na Fig. 3.

No presente trabalho, o vetor de entradas da rede neural é composto pelas temperaturas de entrada no trocador de calor dos fluidos quente (T_{QAV}) e frio ($T_{Óleo}$). Essas variáveis foram escolhidas por representarem as condições externas de operação do trocador de calor e serem independentes do seu funcionamento. A saída da rede neural, ou seja, a variável a ser predita, é vazão de QAV (V_{QAV}), indicadora da incrustação. A estrutura do sistema de predição pode ser vista na Fig. 4.

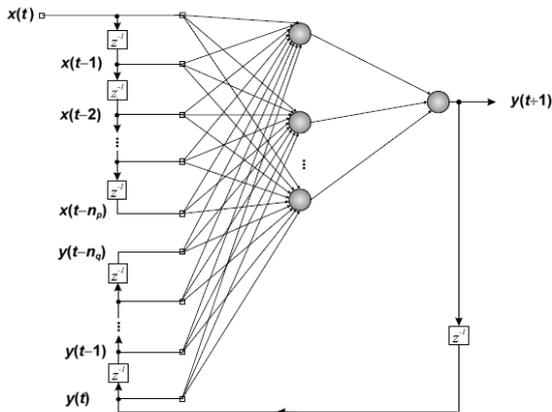


Fig. 3. Rede neural recorrente segundo o modelo NARX

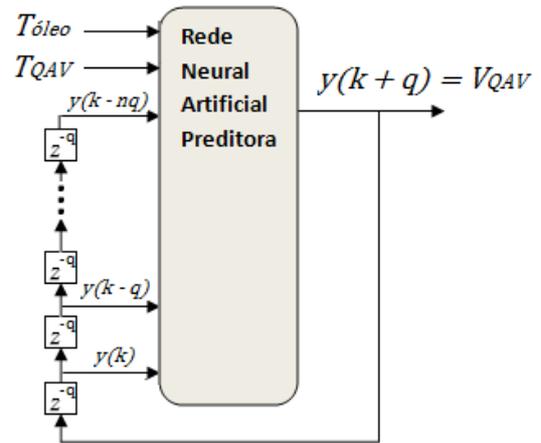


Fig. 4. Estrutura do sistema de predição

Não serão usados regressores nas temperaturas, pois é assumido que os seus valores permanecerão com média constante.

Arquiteturas neurais para sistemas de predição da incrustação em trocadores de calor foram utilizadas também nos trabalhos realizados em [3] e [4]. Além de temperaturas e vazões, os autores do primeiro trabalho dispunham de um conjunto de dados com detalhes finos da composição e propriedades químicas do petróleo. Os autores do segundo trabalho optaram pela resistência térmica como variável indicadora da incrustação.

Outros trabalhos utilizaram redes neurais artificiais para modelar trocadores de calor para tarefas não relacionadas à incrustação, como os desenvolvidos em [5], [6], [7] e [8].

C. Treinamento e Validação do Modelo

O treinamento do modelo foi feito com o auxílio do software matemático MATLAB®. Para essa arquitetura de rede neural, o algoritmo de treinamento é supervisionado, ou seja, os pesos sinápticos são ajustados de forma a minimizar o erro (diferença) entre a resposta apresentada pela rede neural e as saídas desejadas fornecidas para o conjunto de dados de entrada.

Foram separados três conjuntos de dados para treinamento, validação e teste. O primeiro conjunto é usado diretamente nos cálculos de ajuste dos pesos sinápticos das redes neurais. O segundo, de validação, é usado para parar antecipadamente o treinamento caso o erro para esse conjunto de dados esteja aumentando. Esses dois conjuntos foram formados a partir de uma seleção aleatória dos dados dos primeiros 5 ciclos de operação completos do trocador de calor, de forma que ambos os conjuntos contêm dados de todos esses 5 ciclos. O conjunto de teste serve para verificar o desempenho do sistema de predição, pois são dados que nunca foram apresentados durante o treinamento. Foram usados os dados dos outros 5 ciclos de operação completos do trocador de calor para formar esse conjunto.

Em busca da melhor arquitetura, foram treinadas redes neurais com 2, 6 e 12 atrasos de realimentação. Isso significa que a menor rede deve prever a vazão da próxima hora com base nas vazões das últimas 2 horas, enquanto que a maior rede

deve prever a vazão com base nos dados das últimas 12 horas. Ainda em busca da melhor arquitetura, foram treinadas redes neurais com diferentes números de neurônios na camada oculta única. Para cada uma dessas configurações, foram treinadas 10 redes neurais iniciadas com pesos aleatórios. O algoritmo de treinamento utilizado foi o Levenberg-Marquardt. As melhores redes neurais foram selecionadas pelo critério do menor erro médio quadrático para o conjunto de validação.

Algumas das decisões tomadas nesse tópico são discutidas no trabalho de [9]. Os autores discutem diversos pontos sobre o treinamento de redes neurais artificiais para a modelagem de trocadores de calor. Uma conclusão interessante é que, em alguns casos, arquiteturas maiores (com mais neurônios) fornecem melhores resultados, mas existem problemas para os quais redes neurais mais simples são suficientes e fornecem resultados ainda melhores do que as mais complexas.

D. Simulação da Operação

Para verificar o desempenho do sistema de previsão, foram realizados testes simulando a sua operação real, utilizando o conjunto de dados de teste, que nunca foi apresentado durante o treinamento e que contém diversos ciclos de operação do trocador de calor.

Os valores reais das temperaturas e da vazão medidos nas primeiras horas dos ciclos de teste são apresentados à rede neural, que fornece em sua saída a vazão prevista para 1 hora adiante. Este valor é realimentado pela própria rede neural e utilizado para prever mais 1 hora adiante. Dessa forma, o sistema pode prever um número qualquer de horas adiante.

Chama-se de horizonte de previsão o número de horas adiante que o sistema prevê por conta própria, antes de ser realimentado com os dados reais medidos. Os testes realizados verificaram qual a exatidão da rede com um horizonte de previsão de 1 dia (24 horas) até 3 dias (72 horas).

IV. RESULTADOS E DISCUSSÕES

A Tabela 1 contém as características das melhores redes selecionadas. São informados os erros médios quadráticos (EMQ) para o conjunto de dados usado no treinamento e para o conjunto usado apenas para teste. O erro na previsão de 72 horas refere-se ao erro médio obtido quando o sistema prevê até 72 horas a partir do início dos ciclos de operação.

Observa-se um maior erro na previsão de 72 horas em comparação com a previsão de apenas 1 hora. Isso ocorre porque, na previsão de 72 horas, o erro de previsão é continuamente realimentado pela rede neural para realizar os próximos passos de previsão, amplificando esse erro. O erro de treinamento é menor que o de teste, porque o ajuste dos pesos sinápticos foi feito para se adequar especialmente aos dados de treinamento.

A Fig. 5 mostra uma comparação entre a vazão real através do trocador e a vazão prevista pelo sistema para um dos ciclos de operação completo do trocador, aqui chamado de ciclo A. Os dados desse ciclo foram usados na composição dos conjuntos de treinamento e validação da rede neural. Nos gráficos, cada ponto da vazão foi previsto pelo sistema iniciado com os dados reais de certo número de dias no passado, conforme indicado na legenda pelo horizonte de previsão.

A Fig. 6 mostra a mesma comparação, porém para dados de um ciclo de operação completo aqui denominado ciclo B, nunca antes apresentado à rede neural durante o seu treinamento.

Os resultados apresentados demonstram que o sistema foi capaz de generalizar o seu aprendizado e fornecer resultados adequados também para novos conjuntos de dados. O erro obtido pela previsão com horizonte de 3 dias é maior que o obtido pela previsão com horizonte de 1 dia, conforme explicado anteriormente.

TABELA I. INFORMAÇÕES DAS MELHORES REDES TREINADAS

Atrasos	Neurônios ocultos	Horas de previsão	EMQ de treinamento	EMQ de teste
2	16	1	$1,33 \times 10^{-4}$	$2,12 \times 10^{-4}$
		72	$3,2 \times 10^{-3}$	$6,9 \times 10^{-3}$
6	8	1	$1,24 \times 10^{-4}$	$2,90 \times 10^{-4}$
		72	$6,5 \times 10^{-3}$	$1,2 \times 10^{-2}$
12	20	1	$1,26 \times 10^{-4}$	$3,00 \times 10^{-4}$
		72	$3,8 \times 10^{-3}$	$4,7 \times 10^{-3}$

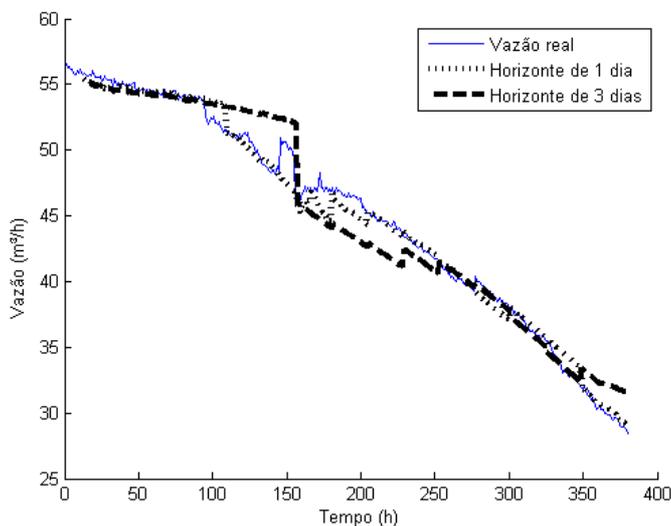


Fig. 5. Comparação entre a vazão real e a prevista para o ciclo A

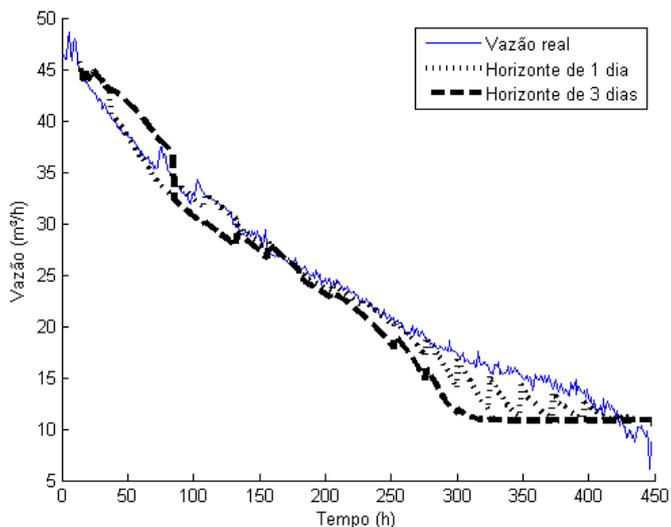


Fig. 6. Comparação entre a vazão real e a prevista para o ciclo B

V. CONCLUSÕES

As redes neurais artificiais do sistema de predição aprenderam as características não lineares do processo da incrustação especificamente para o trocador cujos dados foram coletados. Caso ocorram alterações significativas no processo como, por exemplo, na qualidade do óleo, nas temperaturas médias de operação ou nas vazões fornecidas, é necessário realizar uma nova coleta de dados e treinamento do sistema. Também é interessante realizar outro treinamento ao término de cada novo ciclo de operação. Isso permitiria ao sistema adquirir sempre novas informações e melhorar a sua capacidade de generalização, diminuindo o erro na predição para ciclos futuros. Essa é, inclusive, uma das maiores vantagens do uso de redes neurais artificiais: a sua capacidade de aprendizagem e fácil adaptação a novas situações.

A aplicabilidade da arquitetura do sistema projetado neste trabalho não está limitada apenas a este trocador de calor estudado. A mesma arquitetura poderia ser utilizada em outros trabalhos com outros trocadores de calor reais, bastando ser feita a coleta e tratamento de dados de maneira adequada.

Além dos dados coletados nesse trabalho, outras medições da planta podem de algum modo influenciar a incrustação, apesar de não estarem ligadas diretamente ao trocador de calor. Exemplos de variáveis interessantes que poderiam melhorar o desempenho do sistema de predição são a dosagem de produtos químicos adicionados ao petróleo desde os poços produtores até as estações de tratamento, principalmente o sequestrante de H₂S, e a vazão de água nas dessalgadoras usadas para tratar o petróleo

AGRADECIMENTOS

Os autores agradecem à Petrobras pelo fornecimento de dados e de informações preciosos para a realização desse trabalho e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

REFERÊNCIAS

- [1] Y. Shanrang, X. Zhiming, e S. Lingfang, *Heat Exchanger Fouling and Its Countermeasure*, 2ª ed., Pequim, Science Press, 2004.
- [2] L. Sun, H. Cai, Y. Zhang, S. Yang e Y. Qin, "Research on the fouling prediction of heat exchanger based on wavelet neural network," *IEEE 3rd International Conference on Cybernetics and Intelligent Systems (CIS)*, 2008.
- [3] V. R. Radhakrishnan, M. Ramasamy, H. Zabiri, V. Do Thanh, N. M. Tahir, H. Mukhtar, M. R. Hamdi e N. Ramli, "Heat exchanger fouling model and preventive maintenance scheduling tool," *Applied Thermal Engineering*, vol. 27, ed. 17–18, 2007.
- [4] M. N. Kashani, J. Aminian, S. Shahhosseini, e M. Farrokhi, "Dynamic crude oil fouling prediction in industrial preheaters using optimized ANN based moving window technique," *Chemical Engineering Research and Design*, vol. 90, ed. 7, pp. 938-949, 2012.
- [5] A. Vasickaninová, M. Bakosová, A. Mészáros e J. J. Klemes, "Neural network predictive control of a heat exchanger," *Applied Thermal Engineering*, vol. 31, ed. 13, pp. 2094-2100, 2011.
- [6] M. S. Khan, Y. A. Husnil, M. Getu e M. Lee, "Modeling and simulation of multi-stream heat exchanger using artificial neural network," *Computer Aided Chemical Engineering*, Elsevier, vol. 31, pp. 1196-1200, 2012.

- [7] S. Akbari, C. J. Simonson e R. W. Besant, "Application of neural networks to predict the transient performance of a run-around membrane energy exchanger for yearly non-stop operation," *International Journal of Heat and Mass Transfer*, vol. 55, ed. 21–22, pp. 5403-5416, 2012.
- [8] W. Gang e J. Wang, "Predictive ANN models of ground heat exchanger for the control of hybrid ground source heat pump systems," *Applied Energy*, no prelo.
- [9] D. Wijayasekara, M. Manic, P. Sabharwall e V. Utgikar, "Optimal artificial neural network architecture selection for performance prediction of compact heat exchanger with the EBaLM-OTR technique," *Nuclear Engineering and Design*, vol. 241, ed. 7, pp. 2549-2557, 2011