

8º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

**DETECÇÃO DE FALHAS EM PROCESSOS PETROQUÍMICOS
ATRAVÉS DA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS E
SISTEMAS HÍBRIDOS NEURO-FUZZY**

AUTORES:

Thaylane da Rocha Bezerra, Frede de Oliveira Carvalho, Sílvia Helena Almeida de Oliveira Cassal, Leonardo Domingues, Luan da Silva Barbosa, Samuel Vitor Saraiva, Cleyla Janey Peixoto Calheiros

INSTITUIÇÃO:

Universidade Federal de Alagoas

Este Trabalho foi preparado para apresentação no 8º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás - 8º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás - ABPG, no período de 20 a 22 de outubro de 2015, em Curitiba/PR. Esse Trabalho foi selecionado pelo Comitê Científico do evento para apresentação, seguindo as informações contidas no documento submetido pelo(s) autor(es). O conteúdo do Trabalho, como apresentado, não foi revisado pela ABPG. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões da Associação Brasileira de P&D em Petróleo e Gás. O(s) autor(es) tem conhecimento e aprovação de que este Trabalho seja publicado nos Anais do 8º PDPETRO.

DETECÇÃO DE FALHAS EM PROCESSOS PETROQUÍMICOS ATRAVÉS DA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS E SISTEMAS HÍBRIDOS NEURO-FUZZY

Abstract

This paper discusses the use of different types of Artificial Neural Networks (ANN) and neural-fuzzy hybrid system as tools for fault detection and classification (cluster analysis) of a debutanizer column, part of a desulphurization plant. The column data are available in the literature and variables, such as the temperature measurements of column bottom, were used. The efficiency of the ANN's and the neuro-fuzzy hybrid system for fault detection and classification was evaluated by randomly chosen error insertion on the database. In the evaluation of ANN for fault detection, the network used was Kohonen, which the sensitivity of the network group data with similarities was evaluated. As for the classification, the MLP (Multi-Layer Perceptron) and the hybrid neuro-fuzzy were used. The sensitivity of the networks for a possible industrial application could be proved by the results obtained. The Kohonen network was efficient in grouping the data as well as the classification, which was made in a satisfactory manner, where the MLP and the hybrid system showed similarity in the results.

Introdução

Um dos maiores desafios enfrentados pelo engenheiro químico é assegurar a qualidade dos produtos e a perda mínima de material nos processos industriais. Falhas cada vez mais impactantes demandam grande atenção e investimento por parte das indústrias e do meio acadêmico em sistemas de monitoramento cada vez mais avançados. Técnicas de detecção prévia de falhas, assim como o diagnóstico das mesmas, pode proporcionar uma minimização dos custos operacionais, possibilitando também a prevenção de problemas de diferentes origens, o que justifica o interesse em técnicas de detecção, entre as quais se destacam as que empregam métodos quantitativos baseados em histórico de dados, tais como as redes neurais e os sistemas híbridos.

Uma rede neural torna-se capaz de processar eficientemente dados numéricos após uma etapa denominada treinamento, na qual é submetida a diversos padrões de dados de entrada e saída, e o sistema híbrido neuro-fuzzy representa o sistema *fuzzy* na forma de redes sujeitas a treinamento, por técnicas análogas às redes neurais. Os sistemas *neuro-fuzzy* têm a finalidade de associar a capacidade de aprendizagem das redes neurais à interpretação característica dos sistemas *fuzzy*.


- Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA's) são ferramentas de Inteligência Artificial inspiradas nos neurônios biológicos que possuem a capacidade de se adaptar e de aprender a realizar certa tarefa, ou comportamento, a partir de um conjunto de exemplos dados, baseando-se apenas em dados de entradas e saídas.

A arquitetura de uma rede neural artificial depende diretamente do problema que será tratado pela rede. Como parte da definição da arquitetura da rede tem-se: quantidades de camadas, fluxo de informação e tipos de conexões entre os neurônios (Braga, 2000 apud CARVALHO, 2009). Quanto à quantidade de camadas, as redes podem possuir camada única ou múltiplas camadas. Em relação aos tipos de fluxos de informação elas podem ser do tipo Feedforward (acíclica) ou Feedback (cíclica), no que diz respeito a conectividade das redes, elas podem ser completamente conectadas ou parcialmente conectadas. Por fim, aos algoritmos de adaptação, vamos distinguir entre aprendizagem supervisionada e aprendizagem não supervisionada. Mais detalhes sobre a arquitetura dos modelos aqui utilizados serão discutidos mais adiante.

A Figura 1 ilustra um esquema do mecanismo de funcionamento de uma RNA supervisionada. Nas RNA's supervisionadas os dados de treinamento são acompanhados de correlações com os dados de saída, o que não acontece nas redes não supervisionadas, onde a tarefa de aprendizagem é descobrir correlações entre os dados de treino.

Figura 1 - Mecanismo de funcionamento de uma RNA supervisionada.



É importante salientar que existem diferentes tipos de RNA's e que cada um destes modelos possui suas características próprias quanto à forma de representar e de adquirirem conhecimentos. A seguir são detalhados os modelos utilizados no presente trabalho.

- Lógica Fuzzy

Fuzzy é um termo da língua inglesa que pode ser traduzido como: nebuloso, difuso, entres outros.


A lógica convencional ou clássica usa distinções bem definidas para separar conjuntos, como quando atribuímos a um copo o fato de estar *cheio* ou *vazio*, esse copo não pode estar cheio e vazio ao mesmo tempo. Já a lógica difusa propõe uma escala ou um grau de pertinência, como no nosso exemplo, o copo pode estar *meio cheio* ou *meio vazio*. Assim, é possível notar que, com a Lógica *Fuzzy*, não existe um limite que define os elementos que pertencem ou não a um determinado conjunto, como no caso dos conjuntos *cheio* e *vazio*. Por outro lado, os graus de pertinência dos elementos possuem variações suaves no intervalo real $[0,1]$, representando, assim, de forma mais realista, o conhecimento humano.

Um Sistema Híbrido Neuro-fuzzy (SNF) é um tipo de sistema híbrido incorporado que combina as técnicas de lógica fuzzy e de redes neurais artificiais. Atualmente os sistemas neuro-fuzzy são considerados uma das técnicas mais modernas e poderosas em engenharia quando trata-se de sistemas não-lineares.

Na prática, os sistemas híbridos incorporados são os mais utilizados, pois apresentam o maior grau de hibridização, ao ponto que não é possível a separação entre os dois subsistemas. Nestes sistemas, o grau de hibridização é tão elevado que se pode dizer que o primeiro subsistema contém o segundo, ou vice-versa. Utiliza-se esse tipo de combinação para se obter um sistema mais robusto. Os sistemas fuzzy são apropriados para a modelagem de controladores a partir do conhecimento explícito fornecido pelo especialista, já as RNA's são adequadas na criação do controle baseado no conhecimento implícito embutido em um conjunto de dados, entretanto o desempenho das redes neurais é afetado pelo ajuste de seus parâmetros, como número de camadas escondidas. Portanto, muitos pesquisadores têm tentado integrar estas duas técnicas para gerar um modelo híbrido que possa aproveitar as vantagens de cada uma delas e minimizar suas deficiências.

A idéia básica de um SNF é a construção de um *Sistema de Inferência Fuzzy (FIS)*, numa estrutura paralela distribuída de tal forma que os algoritmos de aprendizado das redes neurais possam ser aproveitados nestes sistemas híbridos para ajustar os parâmetros do *FIS*. A Figura 2 apresenta a estrutura de um SNF que é dividido em 5 camadas.

Figura 2 - Arquitetura básica de um sistema neuro-fuzzy.



A camada de entrada representa as variáveis de entrada, as quais são normalizadas e escalonadas dentro do intervalo numérico [0,1] ou [-1,1]. A segunda camada é a etapa de fuzzificação. Nesta etapa, os intervalos de cada variável de entrada são divididos em diversos níveis (Baixo, Médio e Alto), os quais indicam os pesos da rede para cada entrada. A terceira camada é definida pelas regras do *FIS*, a camada 4 é determinada pelos consequentes das regras, e a camada 5 ou camada de saída é a etapa de defuzzificação, onde se calcula o valor numérico de saída.

- Coluna Debutanizadora

Uma debutanizadora é uma coluna de fracionamento, onde o butano e outros componentes mais leves da gasolina são removidos.

Os dados utilizados no trabalho são de uma coluna que é parte de uma planta de desulfurização e separação de nafta, onde os produtos removidos da corrente de nafta são o butano e o propano. As variáveis utilizadas são listadas na Tabela 1.

Tabela 1. Variáveis da coluna debutanizadora utilizadas no trabalho.

Variáveis	Descrição
U1	Temperatura do topo
U2	Pressão do topo
U3	Refluxo
U4	Fluxo para o próximo processo
U5	Temperatura da 6ª bandeja
U6	Temperatura do fundo
U7	Temperatura do fundo
y	Concentração de butano

Fonte: Adaptado de FORTUNA et. Al (2006).

- Redes Neurais como Classificação

A rede aqui utilizada para classificação foi a MLP, cujo objetivo é determinar a classe pertencente dos dados fornecidos como entrada. De acordo com Osório e Bittencourt (2000), este tipo de rede deve atribuir para cada exemplo que lhe é fornecido uma classe ao qual este exemplo pertence. Portanto, a saída da rede é a classe associada ao exemplo e por consequência, as classes são valores discretos e não contínuos.

A classificação é um caso particular da aproximação de funções onde o valor de saída da rede é discretizado e pertence a um conjunto finito de classes. No caso do aprendizado supervisionado, o conjunto de classes é bem definido e conhecido antes de ser iniciado o processo de aprendizado. As entradas da rede podem ser tanto contínuas, como também

podem ser discretas, o que não deve interferir no fato desta rede ser usada para uma aplicação de classificação (OSÓRIO e BITTENCOURT, 2000).

- **Redes Neurais Como Análise de Agrupamento**

A clusterização (ou análise de agrupamento), também chamado de modelo de Kohonen, é muito interessante, pois permite o aprendizado competitivo com uma auto-organização da rede neural, criando os chamados “mapas de atributos auto-organizáveis” ou SOM (Self- Organizing Map), que são os resultados apresentados pela rede. Segundo Affonso (2011) alguns autores reforçam a ideia de que o SOM, visto como rede neural pode ser aplicada para a obtenção de agrupamentos (clusterização), classificação, estimação, predição e mineração de dados

Segundo Amaral e Pacheco (2010), a análise de agrupamento consiste em um tipo de aprendizado não supervisionado nos quais conjuntos de dados são reunidos a partir de suas similaridades. Os métodos de agrupamento mais comuns necessitam que o número de “clusters” (grupos) seja determinado como ponto de partida e se baseiam na minimização de uma função de distância entre os pontos. Esta rede é uma estrutura de duas camadas de neurônios. A primeira camada é a de entrada e seus neurônios estão completamente interconectados aos neurônios da segunda camada denominada competitiva, que é organizada em um arranjo dependente do objeto a ser mapeado (ALVAREZ e LUQUE, 2003).

Desta forma, utiliza-se neste trabalho as Redes Neurais Artificiais e Sistemas Híbridos Neuro-Fuzzy com aplicação dessas ferramentas em ambiente MatLab® para detecção de falhas nas principais variáveis que governam uma coluna debutanizadora em uma planta de dessulfurização, analisando a aplicabilidade dos modelos como instrumento de prevenção e controle de processos industriais.

Metodologia


A partir dos dados e conhecimentos prévios, realizou-se o estudo da coluna debutanizadora em uma planta de dessulfurização para detecção de falhas nas principais variáveis que governam esta, através de interfaces gráficas disponíveis no MatLab® as quais utilizaram-se as Redes Neurais Artificiais e os Sistemas Híbridos Neuro-Fuzzy.

Resultados e Discussão

- **Redes Neurais como Classificação**

A intensão da rede neural na etapa de classificação é observar se a rede é capaz de identificar e agrupar os dados em classes, com e sem erros. Para isso, foram inseridos aleatoriamente erros de 10% na metade dos dados da variável U7, referente a temperatura de fundo da coluna (Tabela 1), que foram utilizados como entrada da rede. Como saída, adotou-se um conjunto binário de classes correspondentes a entrada, onde o 0 corresponde a dados com erros e o 1 a dados sem erros. A Figura 3 representa a matriz de confusão, que é uma das formas que a rede representa os resultados para a classificação.

Figura 3 - Matriz de Confusão da etapa de classificação.




Fonte: Autores (2015).

Observamos pela matriz de confusão relacionada ao treinamento (Training Confusion Matrix) que 97,5% dos dados foram classificados de forma correta, ainda nessa matriz observamos que 46,2% dos dados a rede atribuiu a classe zero, ou seja, com erro, e 50,1% foram identificados como dados sem erros, o que salienta a eficiência da classificação, pois na realidade foram inseridos erros em 50% dos dados.

Na matriz de confusão – Geral (All Confusion Matrix), podemos ver que 97,6% dos dados foram classificados de forma correta. A Figura 4 mostra o histograma de erro para a classificação.

Figura 4 - Histograma de erro para a classificação.



Fonte: Autores (2015).


- Redes Neurais como Análise de Agrupamento para Detecção de Falhas

Um dos motivos da ocorrência de erros de medição na indústria está associado ao próprio equipamento, erros esses que podem estar associados ao próprio equipamento de medida que pode não estar calibrado, ou ao próprio operador que toma uma medida errada.

Levando isso em consideração, inserimos erros nos dados da debutanizadora, de maneira que pudéssemos retratar uma situação real da indústria. As porcentagens de erro inserido nos dados foram de 10%.

O agrupamento dos dados se dá através da similaridade entre eles, encontrado pelo treinamento da rede. A Figura 5 representa o agrupamento dos dados através das distancias entre seus pesos e é chamada de SOM (Self-Organizing Map), ou mapas auto-organizáveis.

Figura 5 - Distância dos pesos entre os neurônios vizinhos com inserção de erros.




Fonte: Autores (2015).

As linhas em vermelho da figura representam a ligação entre os neurônios, os neurônios são cada hexágono em cinza, e as cores indicam a distância em que cada neurônio se encontra um do outro. Vale destacar que quanto mais claro, mais próximos estão os neurônios um do outro e analogamente quanto mais escuro, mais distantes. Observamos que na Figura 5 temos um agrupamento não muito preciso isso se justifica pela proximidade dos dados, porém a faixa mais escura, mostra que há dados fora de padrão, concluindo dessa forma que a rede neural é uma ferramenta aceitável para detecção de falhas.

Para observarmos o agrupamento dos dados tem-se a Figura 6 que dispõe de forma numérica os acertos (chamados de hits) dentro dos SOM's, referente à Figura 5. Cada valor representa os dados inseridos na rede neural.

Figura 6 - SOM representando a quantidade de dados agrupados relacionado a inserção de erros




Fonte: Autores (2015).

- Sistema Híbrido Neuro-Fuzzy como Classificador

Observando a Figura 7, nota-se que houve um bom nível de representatividade do modelo pela rede neuro-fuzzy. No gráfico de dispersão de dados (Figura 7) podemos verificar que a maioria dos dados simulados está próxima dos dados experimentais, apesar de haver algumas dispersões. Desta forma, o SNF demonstrou de forma

satisfatória sua capacidade em identificar os erros presentes na coluna debutanizadora. Para isso, classificamos os dados de forma binária, sendo o 0 referente aos erros e o 1 aos dados corretos, como já foi citado anteriormente. Esta classificação binária é a variável de saída, a qual é possível estimar através do SNF.

Figura 7 - Dispersão dos dados



Fonte: Autores (2015).

Conclusões

Neste trabalho foi possível avaliar a aplicabilidade de redes neurais através de sua utilização na classificação e agrupamento de dados (detecção de falhas) de uma coluna debutanizadora. Ao analisar os resultados de cada uma das tarefas disponíveis pelas RNA's observamos que seus resultados foram satisfatórios levando em consideração que os dados são considerados reais de uma planta real de Nafta (FORTUNA *et. al* 2006).

Agradecimentos

Ao Laboratório de Sistemas Inteligentes Aplicados pelo suporte oferecido.

Referências Bibliográficas

- ALVAREZ, A. B.; LUQUE, B.. **Rede Neural de Kohonen e Outras Técnicas para Treinamento Não-Supervisionado**. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e Computação. Abril 2003.
- CALHEIROS, C. J. P. **Estudo do processo de hidrotratamento de diesel através de simuladores comerciais e redes neurais artificiais**. Dissertação de Mestrado em Engenharia Química. Universidade Federal de Alagoas. 2014.
- CARVALHO, F. O. **Desenvolvimento de Estratégias Para Utilização de Sistemas Inteligentes Nas Áreas Da Engenharia**. Relatório final. 2009. Entregue a FAPEAL - Fundação de Amparo á Pesquisa do Estado de Alagoas.
- FORTUNA, L.; GRAZIANI, S.; RIZZO, A.; XIBILIA, M. G. **Soft Sensors for Monitoring and Control of Industrial Processes**. Springer. 2007.
- OSÓRIO, F.; BITTENCOURT, J. R. **Sistemas Inteligentes Baseados em Redes Neurais Artificiais Aplicados ao Processamento de Imagens**. I workshop de inteligência artificial. UNISC – Universidade de Santa Cruz do Sul. Departamento de Informática. 2000.