



UNIVERSIDADE FEDERAL DE PERNAMBUCO

CENTRO DE TECNOLOGIA E GEOCIÊNCIAS

ESCOLA DE ENGENHARIA

DEPARTAMENTO DE ENGENHARIA QUÍMICA

DISSERTAÇÃO DE MESTRADO

Implementação de Controle Adaptativo com Base em Rede Neural a

Uma Coluna de Destilação

Antonio Fernando Araújo Britto

Recife – PE

Outubro de 2003

Antonio Fernando Araújo Britto

IMPLEMENTAÇÃO DE CONTROLE ADAPTATIVO COM BASE EM
REDE NEURAL A UMA COLUNA DE DESTILAÇÃO

Dissertação apresentada ao Curso de Mestrado do Departamento de Engenharia Química da Universidade Federal de Pernambuco, como requisito parcial à obtenção do título de Mestre em Engenharia Química.

Orientador: Prof. Dr. Florival Rodrigues de Carvalho
Prof. Dr. Luis Stragevitch
Universidade Federal de Pernambuco

Tese de Mestrado defendida e aprovada em 21 de novembro de 2003 pela banca examinadora constituída pelos professores doutores :

Prof. Dr. Florival Rodrigues de Carvalho

Orientador

Prof. Dr. Carlos Edison Lopes

Professor Titular do Programa de Pós-Graduação em Engenharia Química da UFPE

Prof. Dr. João Teotônio Manzi Monteiro de Araújo

Departamento de Química da Universidade Católica de Pernambuco – UNICAP

AGRADECIMENTOS

A Deus, por me permitir em insistir na busca pelo conhecimento.

A minha esposa, pela sua paciência e compreensão durante o tempo que tive que me dedicar aos meus estudos.

Ao meu orientador Dr. Florival Rodrigues de Carvalho pela sua compreensão e apoio para a realização deste trabalho.

Ao Dr. William Vieira da UFAL por sua experiência e dicas no uso das rotinas relacionadas à rede neural.

Ao Departamento de Engenharia Química da Universidade Federal de Pernambuco, Laboratório de Combustíveis por permitir a utilização de seu espaço e equipamentos.

A Petroflex por permitir utilizar seu processo como fonte de estudo.

Aos colegas Luciano Vieira e José Palha, pelo incentivo recebido durante principalmente o período do cumprimento dos créditos necessários.

SUMÁRIO

1. INTRODUÇÃO.....	1
1.1 Histórico	1
1.2 Descrição do Processo	2
1.3 Rotinas Computacionais	5
2. REVISÃO BIBLIOGRÁFICA.....	8
2.1 Redes Neurais	8
2.2 Redes Neurais Aplicadas a Colunas de Destilação	12
2.3 Controle Adaptativo	15
2.4 Outras Aplicações de Rede Neural a Controle	17
3. METODOLOGIA.....	21
3.1 Introdução	21
3.2 Etapas do Trabalho	21
3.3 Coluna de Destilação	23
3.4 Simulação de Processo	24
3.4.1 Modelagem da Coluna de Destilação	25
3.5 Identificação do Processo	30
3.5.1 Treinamento da Rede Neural	30
3.5.2 Identificação da Coluna de Destilação	36
3.6 Controle Adaptativo	40
3.7 Sintonia da Malha de Controle	43
3.7.1 Sintonia de Lambda	44
3.7.2 Ajuste dos Parâmetros de Sintonia	50
4. RESULTADOS	53

4.1 Simulação da Coluna de Destilação	53
4.2 Identificação das Composições de Carga e de Fundo	63
4.2 Sintonia do Controlador Adaptativo.....	65
5. CONCLUSÕES E RECOMENDAÇÕES	69
6. ANEXOS	71
ANEXO A	72
ANEXO B	75
ANEXO C	78
7. REFERÊNCIAS BIBLIOGRÁFICAS	90

LISTA DE FIGURAS

Figura 1.1. Fluxograma esquemático do sistema existente com a estratégia de controle atual..	4
Figura 2.1. Formas de conexão dos neurônios. 1, 2 e 3 representam as camadas da rede.	9
Figura 2.2. Diagrama de representação de um neurônio da rede.	10
Figura 2.3. Função sigmoidal	11
Figura 2.4. Estratégia para implementação de controle adaptativo.....	16
Figura 2.5. Estratégia para implementação de controle preditivo.	18
Figura 3.1. Representação esquemática da primeira rede	39
Figura 3.2. Representação esquemática da segunda rede.....	43
Figura 3.3. Diagrama genérico de uma malha de controle.....	45
Figura 3.4. Resposta de um controlador genérico.	46
Figura 4.1. Perfis de temperatura para as diferentes composições da carga.	54
Figura 4.2. Ampliação dos perfis de temperatura do prato 1 ao prato 7.	54
Figura 4.3. Teor de leves na carga em 1200 ppm e temperatura em 105 °C.....	56
Figura 4.4. Teor de leves na carga em 1200 ppm e temperatura em 110 °C.....	56
Figura 4.5. Teor de leves na carga em 1200 ppm e temperatura em 115 °C.....	56
Figura 4.6. Teor dos leves na carga em 1700 ppm e temperatura em 105 °C	57
Figura 4.7. Teor dos leves na carga em 1700 ppm e temperatura em 110 °C.....	57
Figura 4.8. Teor dos leves na carga em 1700 ppm e temperatura em 115 °C.....	57
Figura 4.9. Teor dos leves na carga em 2200 ppm e temperatura em 105 °C.....	58
Figura 4.10. Teor dos leves na carga em 2200 ppm e temperatura em 110 °C.....	58
Figura 4.11. Teor dos leves na carga em 2200 ppm e temperatura em 115 °C.....	58
Figura 4.12. Teor dos leves na carga em 2500 ppm e temperatura em 105 °C.....	59
Figura 4.13. Teor dos leves na carga em 2500 ppm e temperatura em 110 °C.....	59

Figura 4.14. Teor dos leves na carga em 2500 ppm e temperatura em 115 °C.	59
Figura 4.15. Teor dos leves na carga em 2700 ppm e temperatura em 105 °C.	60
Figura 4.16. Teor dos leves na carga em 2700 ppm e temperatura em 110 °C.	60
Figura 4.17. Teor dos leves na carga em 2700 ppm e temperatura em 115 °C.	60
Figura 4.18. Teor dos leves na carga em 3000 ppm e temperatura em 105 °C.	61
Figura 4.19. Teor dos leves na carga em 3000 ppm e temperatura em 110 °C.	61
Figura 4.20. Teor dos leves na carga em 3000 ppm e temperatura em 115 °C.	61
Figura 4.21. Teor dos leves na carga em 3200 ppm e temperatura em 105 °C.	62
Figura 4.22. Teor dos leves na carga em 3200 ppm e temperatura em 110 °C.	62
Figura 4.23. Teor dos leves na carga em 3200 ppm e temperatura em 115 °C.	62
Figura.4.24. Identificação da composição dos leves na carga.....	64
Figura.4.25. Identificação da composição dos leves no fundo da coluna.	65
Figura 4.26. Fluxograma esquemático do sistema proposto, destacando a alteração na estratégia de controle.	68

LISTA DE SÍMBOLOS

Símbolos latinos

- H - Matriz Hessiana das derivadas segundas parciais da função objetivo em relação às variáveis independentes.
- $\tilde{~}$
- E - Função objetivo do treinamento da rede neural.
- E_p - Função erro de cada padrão
- f - Função de ativação de cada neurônio.
- j - Índice que representa um neurônio de uma camada qualquer da rede.
- k - Índice que representa uma camada qualquer da rede.
- L - Camada de saída da rede.
- p - Índice que representa um padrão p qualquer.
- S - Saída de um neurônio qualquer.
- Th - Atividade residual do neurônio.
- t - Saída desejada da rede.
- u - Valor de entrada de um processo.
- w - Representação dos pesos das conexões.
- y - Valor da saída de um processo.

Símbolos gregos

- ε - Constante de momento (*momentum*) no método do gradiente conjugado.
- η - Taxa de aprendizado no método do gradiente conjugado.
- θ - *bias* ou *threshold*.
- λ - Função que representa a ativação do neurônio.
- Δ - Variação ou delta de uma unidade qualquer.
- ∇ - Representa o gradiente de uma função.

Símbolos especiais

- \wedge - Símbolo acima das variáveis e representativo da variável predita.
- $_$ - Símbolo abaixo das variáveis e representativo de vetor.

RESUMO

Este trabalho teve como objetivo estudar métodos baseados em Inteligência Artificial (IA), em particular, as Redes Neurais Artificiais (RNA), aplicados em controle de processos.

O sistema a ser estudado é composto de uma coluna de destilação existente na planta da PETROFLEX de Cabo de Santo Agostinho, a qual faz parte do sistema de purificação de solvente. O principal processo de produção da PETROFLEX se dá através da reação de polimerização do Butadieno-1,3 formando a borracha sintética. Ocorre através do mecanismo conhecido como polimerização aniônica em solução em presença de um iniciador, onde o solvente, principalmente constituído de N-Hexano e Ciclohexano, é o meio no qual a reação ocorre. A mistura de borracha sintética e solvente, conhecida como cimento é encaminhada para um sistema onde o solvente é separado da borracha e em seguida, é enviado ao sistema de purificação de solvente.

A função do sistema em estudo é remover impurezas representadas por compostos leves, na faixa de 4 átomos de carbono, que contaminando a corrente de solvente traz grandes perturbações ao sistema de reação. Esses são principalmente o cis-Buteno-2 e o próprio Butadieno-1,3 não convertido. Embora, em si não sejam contaminantes, sua presença normalmente está associada a teores bastante diminutos de outros compostos altamente indesejáveis como os acetilenos (Etilacetileno, Vinilacetileno ou Metilacetileno). A coluna de destilação opera com seus controladores ajustados em valores fixos, devido ao fato de não se conhecer a todo instante a composição da carga e a de fundo da coluna. Isto nem sempre produz bons resultados e na maior parte do tempo gasta-se mais energia que o necessário.

Propõe-se, então, a implementação de um sistema de controle que deverá se ajustar às diferentes condições de operação, como uma consequência da variação da composição da carga. O trabalho foi constituído de três etapas : Na primeira, utilizou-se o simulador de processos ASPEN PLUS™ para simular e validar as condições operacionais da coluna de destilação; na segunda, utilizou-se o conjunto de dados gerados pelo simulador para realizar a identificação do processo via uma rede neural (RNA). Na terceira, foi implementado um controlador adaptativo, onde o sinal de processo para o controlador vem da RNA.

O simulador de processos ASPEN PLUS™ se baseia em modelos fenomenológicos. A RNA a ser implementada e treinada, tomará por base os dados gerados por este simulador, numa etapa denominada de identificação do processo, resultando em mais agilidade à obtenção dos dados necessários ao treinamento da rede.

O controle do processo, denominado de Controle Adaptativo fará uso desta rede, que será responsável pela predição do sinal de controle. O controlador adaptativo baseado no modelo de rede neural, modifica a sintonia do controlador da variável controlada atuando de acordo com o critério especificado, enquanto ao mesmo tempo, o sinal de processo para o controlador adaptativo é predito pelo modelo de rede neural.

Os resultados obtidos pelo simulador demonstraram um alto grau de compatibilidade com as condições reais da planta, dando boa representatividade ao processo. A RNA também após treinada e validada apresentou um erro inferior a 0,9 %. De posse destas informações, realizou-se a implementação de um controlador adaptativo para a vazão de refluxo da coluna de destilação, onde definiu-se equações relacionando os parâmetros de sintonia do controlador ao teor de leves na corrente de carga da coluna.

A opção de implementação de um controlador adaptativo na coluna de destilação da PETROFLEX deverá proporcionar uma melhor estabilidade na qualidade das especificações dos produtos da coluna devido à maior sensibilidade que este tipo de controle apresenta,

adequando-se melhor às perturbações e apresentando uma performance superior ao controle regulatório padrão baseado em controladores PID (Proporcional-Integral-Derivativo).

ABSTRACT

The purpose of this work is to study methods based on Artificial Intelligence (AI), in particular, the Artificial Neural Networks (ANN), applied in process control.

The system to be studied is composed of a distillation column in the existing plant of PETROFLEX in Cabo de Santo Agostinho, which is a part of purification solvent system. The main production process of PETROFLEX takes place through a polymerization reaction of 1,3-Butadiene giving the synthetic rubber. It occurs through a reaction mechanism known as solution anionic polymerization in presence of a initiator, where the solvent, mainly constituted of N-Hexane and Cyclohexane, it is the medium where the reaction takes place. The blend of synthetic rubber and solvent, known as cement is directed to a system where the solvent is separated from the rubber and so, it is sent to the solvent system purification.

The main purpose of the studied system is to remove impurities represented by light components, in the range of 4 atoms of carbon, which by contaminating the solvent stream brings great disturbances to the reaction system. The lights components presents are mainly the cis-Butene-2 and the unconverted 1,3-Butadiene. However, these compounds itself are not contaminants, and their presence usually is associated with a very low contents of others highly undesirable compounds like the Acetylenes (Ethyl acetylene, Vinyl acetylene or Methyl acetylene). The distillation column runs with its controllers set in fixed values, due to the fact of not to know in each moment the feed composition and the bottoms composition. Not always this can lead to a good results and most time it is spent more energy than the necessary.

In this study it is proposed the implementation of a control system which should adjust itself to the different operating conditions, as a consequence of the feed composition variation. The work was constituted in three stages: in the first stage, the process simulator ASPEN PLUS™ was used to simulate and validate the operational conditions of the distillation column; in the second, the set of data generated by the simulator was used to accomplish the process identification by using a Artificial Neural Network (RNA); in the third, a adaptive controller was implemented, where the process sign to the controller comes from the RNA.

The process simulator ASPEN PLUS™ is based on phenomenological models. The RNA to be implemented and trained will take as basis the data generated from this simulator in a stage called process identification. The use of the simulator will give more agility in getting the necessary data to train the net.

The control of the process, denominated of Adaptive Control will use this net, which will be responsible for the prediction of the sign of control. The adaptive controller based on the neural network model, modifies the controller's tuning of the controlled variable acting according with a specified criteria, while at the same time, the process sign for the adaptive controller is predicted by the neural network. model.

The results obtained by the process simulator demonstrated a high compatibility degree with the plant actual conditions, giving good representativeness to the process. After trained and validated the RNA presented an error less than 0,9 %. With this information a implementation of a Adaptive Controller took place for the reflux flow rate of the distillation column, where it was defined equations relating the tuning controller parameters to the lights content in the feed to the column.

The option of the adaptive controller implementation in the column distillation of PETROFLEX plant should provide a better stability in the quality of the specifications of the

products of the column due to the higher sensibility that this control type presents, being adapted better to the disturbances and presenting a better performance than the standard control based on controllers PID (Proportional-Integral-Derivative).