



**Leonardo Guilherme Caetano Corrêa**

**Inferência da Qualidade de Produtos de Destilação  
Utilizando Redes Neurais Artificiais e  
Filtro de Kalman Estendido**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial para  
obtenção do título de Mestre pelo Programa de Pós-  
Graduação em Engenharia Elétrica da PUC-Rio.

Orientador: Carlos Roberto Hall Barbosa

Rio de Janeiro, maio de 2005.



Leonardo Guilherme Caetano Corrêa

Inferência da Qualidade de Produtos de  
Destilação Utilizando Redes Neurais Artificiais e  
Filtro de Kalman Estendido

**Dissertação apresentada como requisito parcial  
para obtenção do grau de Mestre pelo Programa de  
Pós-Graduação em Engenharia Elétrica do  
Departamento de Engenharia Elétrica do Centro  
Técnico Científico da PUC-Rio. Aprovada pela  
Comissão Examinadora abaixo assinada.**

Prof. Carlos Roberto Hall Barbosa  
Orientador  
**Departamento de Engenharia Elétrica – PUC-Rio**

Profa. Marley Maria B. R. Vellasco  
**Departamento de Engenharia Elétrica – PUC-Rio**

Profa. Karla Tereza Figueiredo Leite  
**Departamento de Engenharia Elétrica – UERJ**

Profa. Rita de Cássia B. S. Berlin  
**Departamento de Eletrônica e Telecomunicações – CENPES**

Prof. José Eugenio Leal  
**Coordenador Setorial do Centro  
Técnico Científico - PUC-Rio**

Rio de Janeiro, 24 de maio de 2005.

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

**Leonardo Guilherme Caetano Corrêa**

Graduou-se em Engenharia Elétrica com ênfase em Eletrônica no CEFET-RJ (Centro Federal de Educação Tecnológica Celso Suckow da Fonseca) em 2002.

Ficha Catalográfica

Corrêa, Leonardo Guilherme Caetano

Inferência da qualidade de produtos de destilação utilizando redes neurais artificiais e filtro de Kalman estendido / Leonardo Guilherme Caetano Corrêa; orientador: Carlos Barbosa Hall. – Rio de Janeiro: PUC, Departamento de Engenharia Elétrica, 2005.

57 f. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica.

Inclui referências bibliográficas.

1. Engenharia elétrica – Teses. 2. Inteligência Computacional Aplicada. 3. Redes Neurais Artificiais. 4. Filtro de Kalman Estendido. 5. Inferência de Qualidade. I. Hall, Carlos Barbosa. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

**CDD: 621.3**

## Agradecimentos

A Deus por me ajudar a persistir e a ultrapassar os obstáculos presentes na vida.

Ao orientador Professor Carlos Roberto Hall Barbosa pela paciência, estímulo, auxílio e confiança dispensados para a realização deste trabalho.

À Pontifícia Universidade Católica do Rio de Janeiro (PUC – Rio) pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Aos professores que participaram da Comissão examinadora: Marley Vellasco, Karla Figueiredo e Rita de Cássia Berlim.

Aos meus pais Francisco e Hilda e minha irmã Eliza pelo apoio constante.

À minha esposa Priscila Marques Dias com seus preciosos conselhos.

A todos os amigos e familiares que de uma forma ou de outra me estimularam e me ajudaram no meu desempenho.

## Resumo

Corrêa, Leonardo Guilherme Caetano; Inferência da qualidade de produtos de destilação utilizando redes neurais artificiais e filtro de Kalman estendido. Rio de Janeiro, 2005. 57p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica Rio de Janeiro.

Atualmente cresce o interesse científico e industrial na elaboração de métodos de controle não lineares. Porém, estes modelos costumam ter difícil implementação e um custo elevado até que se obtenha uma ferramenta de controle confiável. Desta forma, estudos na área de métodos de apoio à decisão procuram desenvolver aplicações inteligentes com custos reduzidos, capazes de executar controles industriais avançados com excelentes resultados, como no caso da indústria petroquímica. Na destilação de derivados de petróleo, por exemplo, é comum fazer uso de análises laboratoriais de amostras para identificar se uma substância está com suas características físico-químicas dentro das normas internacionais de produção. Além disso, o laudo pericial desta análise permite regular os instrumentos da planta de produção para que se consiga um controle mais acurado do processo e, conseqüentemente, um produto final com maior qualidade. Entretanto, apesar da análise laboratorial ter maior acurácia nos resultados que avaliam a qualidade do produto final, exige, às vezes, muitas horas de análise, o que retarda o ajuste dos equipamentos de produção, reduzindo a eficiência do processo e aumentando o tempo de produção de certos produtos, que precisam ter sua composição, posteriormente, corrigida com outros reagentes. Outra desvantagem está relacionada aos custos de manutenção e calibração dos instrumentos localizados na área de produção, pois, como estes equipamentos estão instalados em ambientes hostis, normalmente sofrem uma degradação acelerada, o que pode gerar leituras de campo erradas, dificultando a ação dos operadores. Em contrapartida, dentre os métodos inteligentes mais aplicados em processos industriais químicos, destacam-se as redes neurais artificiais. Esta estrutura se inspira nos neurônios biológicos e no processamento paralelo do cérebro humano, tendo assim a capacidade de armazenar e utilizar o conhecimento experimental que for a ela apresentado. Apesar do bom resultado que a estrutura de redes neurais gera, existe uma desvantagem relacionada à necessidade de re-treinamento da rede

quando o processo muda seu ponto de operação, ou seja, quando a matéria-prima sofre algum tipo de mudança em suas características físico-químicas. Como solução para este problema, foi elaborado um método híbrido que busca reunir as vantagens de uma estrutura de redes neurais com a habilidade de um filtro estocástico, conhecido por filtro de Kalman estendido. Em termos práticos, o filtro atua em cima dos pesos sinápticos da rede neural, atualizando os mesmos em tempo real e permitindo assim que o sistema se adapte constantemente às variações de mudança de processo. O sistema também faz uso de pré-processamentos específicos para eliminar ruídos dos instrumentos de leitura, erros de escalas e incompatibilidade entre os sinais de entrada e saída do sistema, que foram armazenados em frequências distintas; o primeiro em minutos e o segundo em horas. Além disso, foram aplicadas técnicas de seleção de variáveis para melhorar o desempenho da rede neural no que diz respeito ao erro de inferência e ao tempo de processamento. O desempenho do método foi avaliado em cada etapa elaborada através de diferentes grupos de testes utilizados para verificar o que cada uma delas agregou ao resultado final. O teste mais importante, executado para avaliar a resposta da metodologia proposta em relação a uma rede neural simples, foi o de mudança de processo. Para isso, a rede foi submetida a um grupo de teste com amostras dos sinais de saída somados a um sinal tipo rampa. Os experimentos mostraram que o sistema, utilizando redes neurais simples, apresentou um resultado com erros MAPE em torno de 1,66%. Por outro lado, ao utilizar redes neurais associadas ao filtro de Kalman estendido, o erro cai à metade, ficando em torno de 0,8%. Isto comprova que, além do filtro de Kalman não destruir a qualidade da rede neural original, ele consegue adaptá-la a mudanças de processo, permitindo, assim, que a variável de saída seja inferida adequadamente sem a necessidade de re-treinamento da rede.

## **Palavras-chave**

Inteligência Computacional, Redes Neurais Artificiais, Filtro de Kalman Estendido, Inferência de Qualidade.



## Abstract

Corrêa, Leonardo Guilherme Caetano; Inference of the quality of distillation products using artificial neural nets and filter of extended Kalman. Rio de Janeiro, 2005. 57p. MSc Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica Rio de Janeiro.

Nowadays, scientific and industrial interest on the development of non-linear control systems increases day after day. However, before these models become reliable, they must pass through a hard and expensive implementation process. In this way, studies involving decision support methods try to develop low cost intelligent applications to build up advanced industrial control systems with excellent results, as in the petrochemical industry. In the distillation of oil derivatives, for example, it is very common the use of laboratorial sample analysis to identify if a substance has its physical-chemistry characteristics in accordance to international production rules. Besides, the analyses results allow the adjustment of production plant instruments, so that the process reaches a thorough control, and, consequently, a final product with higher quality. However, although laboratory analyses are more accurate to evaluate final product quality, sometimes it demands many hours of analysis, delaying the adjustments in the production equipment. In this manner, the process efficiency is reduced and some products have its production period increased because they should have its composition corrected with other reagents. Another disadvantage is the equipments' maintenance costs and calibration, since these instruments are installed in hostile environments that may cause unaccurate field measurements, affecting also operator's action. On the other hand, among the most applied intelligent systems in chemical industry process are the artificial neural networks. Their structure is based on biological neurons and in the parallel processing of the human brain. Thus, they are capable of storing and employing experimental knowledge presented to it earlier. Despite good results presented by neural network structures, there is a disadvantage related to the need for retraining whenever the process changes its operational point, for example, when the raw material suffers any change on its physical-chemistry characteristics. The proposed solution for this problem is a hybrid method that joins the advantages of a neural network structure with the ability of a stochastic filter, known as extended Kalman filter. This filter acts in the synaptic weights, updating them on-



line and allowing the system to constantly adapt itself to process changes. It also uses specific pre-processing methods to eliminate scale mistakes, noises in instruments readings and incompatibilities between system input and output, which are measured with different acquisition frequencies; the first one in minutes and the second one in hours. Besides, variable selection techniques were used to enhance neural network performance in terms of inference error and processing time. The method's performance was evaluated in each process step through different test groups used to verify what each step contributes to the final result. The most important test, executed to analyse the system answer in relation to a simple neural network, was the one which simulated process changes. For that end, the network was submitted to a test group with output samples added to a ramp signal. Experiments demonstrated that a system using simple neural networks presented results with MAPE error of about 1,66%. On the other hand, when using neural networks associated to an extended Kalman filter, the error decreases to 0,8%. In this way, it's confirmed that Kalman filter does not destroy the original neural network quality and also adapts it to process changes, allowing the output inference without the necessity of network retraining.

## **Keywords**

Computational Intelligence, Artificial Neural Networks, Extended Kalman Filter, Quality Inference.

# Sumário

1 Introdução	12
2 Abordagens Anteriores	14
3 Filtro de Kalman	18
4 Solução Proposta	23
4.1. Pré-Processamento	23
4.1.1. Limpeza	25
4.1.2. Segmentação	27
4.1.3. Validação	28
4.1.4. Normalização	30
4.1.5. Equalização	32
4.2. Seleção de Variáveis	33
4.2.1. Correlação Cruzada	34
4.2.2. LSE (Least Squares Estimator)	36
4.2.3. Combinação dos Métodos	38
4.3. Padrões de Treinamento	40
4.4. Inferência	41
5 Avaliação Experimental	46
6 Conclusões	52
Referências Bibliográficas	55

## Lista de figuras

Figura 1: Algoritmo do filtro de Kalman.	20
Figura 2: Algoritmo do filtro de Kalman estendido.	22
Figura 3: Diagrama de blocos do sistema de inferência da qualidade.	23
Figura 4: Etapas de pré-processamento.	25
Figura 5: Dados de entrada (a) e de saída (b) após a limpeza de dados.	26
Figura 6: Amostra do sinal de saída depois da segmentação.	27
Figura 7: Processo de segmentação.	28
Figura 8: Densidade de probabilidade = Distribuição Gaussiana.	29
Figura 9: Exemplo de valores que excedem a faixa limite de um instrumento.	29
Figura 10: Sinal do instrumento # 1 antes da normalização.	31
Figura 11: Sinal do instrumento # 1 depois da normalização.	31
Figura 12: Histograma do sinal de saída antes (a) e depois (b) da equalização.	32
Figura 13: Etapas de seleção de variáveis.	33
Figura 14: Correlação cruzada máxima de uma janela.	35
Figura 15: Valores da correlação cruzada máxima de cada instrumento e seus respectivos atrasos.	36
Figura 16: Valores do LSE de cada instrumento e seus respectivos atrasos.	38
Figura 17: Combinação dos resultados das duas técnicas de seleção de variáveis.	39
Figura 18: Definição dos padrões de entrada e saída.	41
Figura 19: Estrutura da rede neural combinada com o FKE.	42
Figura 20: Exemplo de uma estrutura RNA.	44
Figura 21: Saída de dados original (a) e somada com uma rampa (b).	48
Figura 22: Inferência da saída usando RNA.	50
Figura 23: Inferência da saída usando RNA com FKE.	50