

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA QUÍMICA

**ÁREA DE CONCENTRAÇÃO
SISTEMA DE PROCESSOS QUÍMICOS E INFORMÁTICA**

**CONTROLE *FEEDFORWARD-FEEDBACK* APLICADO ÀS COLUNAS DE
ABSORÇÃO DO PROCESSO DE PRODUÇÃO DE ETANOL POR
FERMENTAÇÃO**

Autor: Eduardo Eyng.

Orientadora: Dra. Ana Maria Frattini Fileti.

Tese de Doutorado apresentada à Faculdade de Engenharia Química como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Química.

Campinas - São Paulo
Dezembro/2008

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE -
UNICAMP

Ey56c Eyng, Eduardo
Controle de feedforward-feeedback aplicado às
colunas de absorção do processo de produção de etanol
por fermentação / Eduardo Eyng. --Campinas, SP: [s.n.],
2008.

Orientador: Ana Maria Frattini Fileti.
Tese de Doutorado - Universidade Estadual de
Campinas, Faculdade de Engenharia Química.

1. Controle de processo. 2. Redes neurais
(Computação). I. Fileti, Ana Maria Frattini. II.
Universidade Estadual de Campinas. Faculdade de
Engenharia Química. III. Título.

Título em Inglês: Feedforward-feedback control applied to the absorption
columns of the ethanol production process by
fermentation

Palavras-chave em Inglês: Process control, Neural network

Área de concentração: Sistemas de Processos Químicos e Informática

Titulação: Doutor em Engenharia Química

Banca examinadora: Antônio José Gonçalves da Cruz, Jones Erni Schmitz,
Vivaldo Silveira Jr, Sandra Lúcia da Cruz

Data da defesa: 18/12/2008

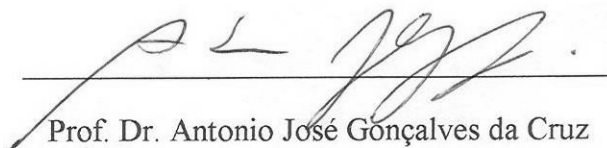
Programa de Pós Graduação: Engenharia Química

Tese de doutorado defendida por Eduardo Eyng e aprovada, em 18 de dezembro de 2008,
pela banca constituída pelos seguintes doutores:



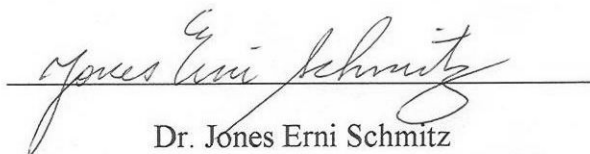
Profa. Dra. Ana Maria Frattini Fileti – Orientadora

FEQ/UNICAMP



Prof. Dr. Antonio José Gonçalves da Cruz

UFSCAR



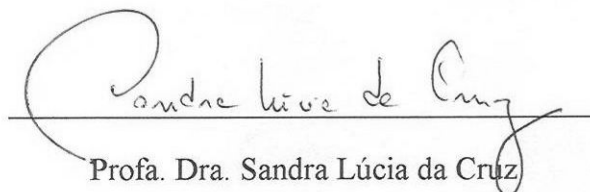
Dr. Jones Erni Schmitz

Empresa ATENATEC



Prof. Dr. Vivaldo Silveira Jr

FEA/UNICAMP



Profa. Dra. Sandra Lúcia da Cruz

FEQ/UNICAMP

Este exemplar corresponde à versão final da Tese de Doutorado em Engenharia
Química.

A handwritten signature in black ink, appearing to read 'Ana Maria Frattini Fileti', is written over a horizontal line. The signature is stylized, with a large loop at the end.

Profa. Dra. Ana Maria Frattini Fileti

Orientadora

AGRADECIMENTOS

A Deus acima de tudo, pela iluminação e força.

À minha esposa, pelo incentivo, compreensão, paciência e amor.

Aos meus pais, pelo apoio incondicional.

À Dra. Ana Maria Frattini Fileti, pela orientação, experiência e sugestões.

À FAPESP pelo apoio financeiro.

RESUMO

O etanol perdido por evaporação durante o processo de produção por fermentação pode ser recuperado por uma coluna de absorção, a qual requer um sistema de controle robusto de acordo com sua complexidade. Este equipamento também é utilizado no tratamento do CO_2 , um co-produto deste processo. Neste sentido, no presente trabalho foi proposto e testado, o emprego de controladores *feedforward-feedback*, baseados em modelo inverso de redes neurais, os quais manipulam as vazões de solvente que são alimentados às colunas, para controlar a concentração de etanol na corrente gasosa à saída da primeira coluna, e a concentração de água residual no efluente gasoso da segunda.

Simulações foram feitas, sendo abordado tanto o problema regulatório quanto o problema servo para as duas colunas de absorção do processo estudado. O desempenho do controlador neural foi superior ao apresentado por um controlador convencional PID, para ambas as colunas de absorção estudadas, pois o tempo de resposta, assim como o *overshoot* foi menor. A superioridade do controlador neural foi comprovada pelos valores obtidos para os parâmetros ITAE (integral do erro absoluto ponderada pelo tempo), IAE (integral do erro absoluto) e ISE (integral do quadrado do erro).

Outro objetivo deste trabalho foi avaliar a influência das incertezas nos sensores sobre o desempenho do sistema de controle. Foram testados três níveis: 5, 10 e 15%, sendo as incertezas inseridas nas variáveis de entrada do tipo concentração de etanol/água residual na corrente gasosa. Para a coluna de recuperação de etanol, tanto para o problema regulatório quanto servo, nenhum controlador conseguiu estabilizar a variável controlada no *set point*, no entanto, quando empregado o controlador neural a amplitude da faixa de oscilação da variável controlada foi menor para todos os níveis de incerteza testados. Já para a coluna de tratamento de CO_2 , os controladores encontraram dificuldades em manter a estabilidade do sistema. Neste sentido, o controlador neural apresentou um desempenho satisfatório para incertezas de 5 e 10%, enquanto que o PID não conseguiu manter o sistema estável para incertezas superiores a 5%.

Com base nos testes realizados foi constatado que o controlador neural proposto constitui uma opção atrativa para o controle das colunas de absorção do processo de

produção de etanol por fermentação, principalmente quando os níveis de incerteza forem de até 10%.

ABSTRACT

Some of ethanol lost by evaporation during its fermentation production process may be recovered using an absorption column, which requires a robust control system. This equipment also is used on carbonic gas treatment, a by-product of this process. In the present work, the development of nonlinear feedforward-feedback controllers, based on a neural network inverse model, was proposed and tested to manipulate the absorbent flow rates in order to control the residual ethanol concentration in the effluent gas phase at the first absorption column, and the residual water at the second one.

Simulation studies were carried out for the regulator and servo problem, for both absorption columns studied. The neural controller proposed outperformed a conventional PID, because the response time, and also the overshoot were smaller when the neural controller was applied. The results were confirmed by the ITAE (integral of time multiplied by the absolute error), IAE (integral of absolute error) and ISE (integral of square error) parameters.

The measurement uncertainties influence on control system performance was tested for three levels: 5, 10 and 15%. The uncertainties were introduced on ethanol/residual water concentration on gas phase. For the ethanol recovery column, neither PID nor the neural controller drove the controlled variable exactly to the set point, however, the neural controller provided a smaller oscillation for all uncertainty levels tested, for regulator and servo problem. The neural controller also outperformed PID in CO₂ treatment column. For the regulator and servo problems the neural controller successfully proceeded when the uncertainty level was 5% or 10%, while the PID did not deal adequately with uncertainties above 5%.

Therefore, the proposed neural controller proved be an attractive control solution for the absorption columns of ethanol production process by fermentation, especially when the input variables carry small uncertainties (less than 10%) from the sensors.

SUMÁRIO

NOMENCLATURA	xiii
 CAPÍTULO 1 – INTRODUÇÃO	 01
1.1 OBJETIVOS	06
 CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA	 07
2.1 INTRODUÇÃO	08
2.2 COLUNAS DE ABSORÇÃO	08
2.2.1 MODELO DINÂMICO DA COLUNA (MAIA, 1994)	12
2.3 REDES NEURAIS ARTIFIAIS	18
2.3.1 TREINAMENTO	18
2.3.2 PERCEPTRON	19
2.3.3 MULTICAMADAS DE NEURÔNIOS ARTIFICIAIS	21
2.3.3.1 ALGORITMO DA RETROPROPAGAÇÃO (OU <i>BACKPROPAGATION</i>)	22
2.3.3.2 ALGORITMO DE LEVENBERG-MARQUARDT COM REGULARIZAÇÃO BAYESIANA	30
2.4 CONTROLADOR PROPORCIONAL INTEGRAL DERIVATIVO (PID)	33
2.5 PROPOSTA DA TESE	33
 CAPÍTULO 3 – ESTRATÉGIA DE CONTROLE PARA COLUNA DE ABSORÇÃO DE PRATOS	 35
3.1 INTRODUÇÃO	36
3.2 SISTEMA ESTUDADO	36
3.3 CONTROLE VIA REDES NEURAIS	39
3.3.1 CONSTRUÇÃO DA REDE NEURAL	39
3.3.2 TREINAMENTO DA REDE NEURAL	43
3.4 SINTONIA DOS PARÂMETROS DO CONTROLADOR PID	45
3.5 IMPLEMENTAÇÃO DAS INCERTEZAS NOS SENSORES	46
3.6 CRITÉRIOS DE AVALIAÇÃO DE DESEMPENHO	47

CAPÍTULO 4 – RESULTADOS	49
4.1 INTRODUÇÃO	50
4.2 RESUMO DOS RESULTADOS DISPONÍVEIS NA LITERATURA	50
4.3 RESULTADOS PRELIMINARES: AVALIAÇÃO DA NÃO LINEARIDADE DO SISTEMA	55
4.4 CONSTRUÇÃO DO CONJUNTO DE DADOS DE TREINAMENTO E VALIDAÇÃO PARA AS REDES NEURAIS ARTIFICIAIS	59
4.5 CONSTRUÇÃO DO PROGRAMA COMPUTACIONAL PARA CRIAÇÃO E TREINAMENTO DA REDE NEURAL ARTIFICIAL	64
4.6 IMPLEMENTAÇÃO DO CONTROLADOR NEURAL BASEADO NO MODELO INVERSO DE REDES NEURAIS	65
4.6.1 DETERMINAÇÃO DA ARQUITETURA DA REDE	65
4.6.2 DESEMPENHO DO CONTROLE RNA	72
4.7 INSERÇÃO DE DISTÚRBO NÃO PREVISTO NA ETAPA DE TREINAMENTO (X_0) E POSTERIOR ATUALIZAÇÃO DESTE BANCO DE DADOS	75
4.8 AVALIAÇÃO DA AÇÃO <i>FEEDBACK</i> DO CONTROLADOR RNA	77
4.9 AVALIAÇÃO DA AÇÃO <i>FEEDFORWARD</i> DO CONTROLADOR RNA	80
4.10 ALTERAÇÃO DO TEMPO DE AMOSTRAGEM DEVIDO AO TEMPO MORTO NAS MEDIDAS DE COMPOSIÇÃO	82
4.10.1 TREINAMENTO DA REDE	82
4.10.2 SINTONIA DOS PARÂMETROS DO PID	83
4.10.3 DESEMPENHO DOS CONTROLADORES OPERANDO A UM TEMPO DE AMOSTRAGEM SUPERIOR AO IDEAL	84
4.11 PROBLEMA SERVO	87
4.11.1 CONSTRUÇÃO E TREINAMENTO DAS RNAS PARA O PROBLEMA SERVO	87
4.11.2 DETERMINAÇÃO DAS ARQUITETURAS DAS REDES PARA O PROBLEMA SERVO	89
4.11.3 SINTONIA DOS PARÂMETROS DO PID PARA O PROBLEMA SERVO	93
4.11.4 DESEMPENHO DO CONTROLADOR RNA PARA O PROBLEMA SERVO	95
4.12 INSERÇÃO DA INCERTEZA DOS SENSORES	99

4.12.1 DETERMINAÇÃO DA ARQUITETURA DE REDE	99
4.12.2 PARÂMETROS DO PID PARA O SISTEMA OPERANDO SOB A INFLUÊNCIA DAS INCERTEZAS NOS SENSORES	122
4.12.3 DESEMPENHO DO CONTROLADOR RNA FRENTE ÀS INCERTEZAS NOS SENSORES	123
CAPÍTULO 5 – CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	133
5.1 CONCLUSÕES	134
5.2 SUGESTÕES PARA TRABALHOS FUTUROS	136
REFERÊNCIAS BIBLIOGRÁFICAS	137
ANEXOS	140
ANEXO 01 – PROGRAMA COMPUTACIONAL EM MATLAB® MODELO_COLUNA_DE_ABSORCAO_ETANOL.M	143
ANEXO 02 – PROGRAMA COMPUTACIONAL EM MATLAB® REDE_COLUNA_DE_ABSORCAO_TREINAMENTO_ ETANOL.M	151
ANEXO 03 – ARQUIVOS SECUNDÁRIOS EM MATLAB®	155
ANEXO 04 – ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - MODELO_COLUNA_DE_ABSORCAO_CO2.M	157
ANEXO 05 - ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - REDE_TREINAMENTO_COLUNA_DE_ ABSORCAO_CO2.M	161
ANEXO 06 - ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - MODELO_COLUNA_DE_ABSORCAO_ SERVO_ETANOL.M	163
ANEXO 07 - ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - REDE_TREINAMENTO_COLUNA_DE_ ABSORCAO_SERVO_ETANOL.M	167
ANEXO 08 - ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - MODELO_COLUNA_DE_ABSORCAO_	

SERVO_CO2.M	171
ANEXO 09 - ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM MATLAB® - REDE_TREINAMENTO_COLUNA_DE_ ABSORCAO_SERVO_CO2.M	175

NOMENCLATURA

A_p = área do prato

b_k = Termo Limiar

c = constante

d = saída desejada para a rede

e_j = erro correspondente a uma iteração para o neurônio j

E = erro correspondente a todos os nódulos de saída

\overline{E} = função objetivo

f = fator de supressão

FO = função objetivo para o método de Levenberg-Marquardt com regularização Bayesiana

G = vazão de gás

H = aproximação da matriz de Hess

h_v = Altura do vertedouro

ISE = integral do quadrado do erro

J = Matriz Jacobiana

k_p = ganho do processo

k_c = ganho do controlador

L = vazão de solvente

L_0 = vazão de solvente à entrada da coluna

L_w = comprimento do vertedouro

M = massa molar de líquido contida em cada estágio

MSE = média dos quadrados dos erros

N = número de estágios

N' = número total de parâmetros da rede

SSE = Soma dos quadrados dos erros

SSW = Soma dos quadrados dos pesos

T = horizonte do processo

T_a = tempo de amostragem

t_d = tempo morto do processo

U = horizonte de controle

V = horizonte de predição

v_k = entrada da função de ativação

w_{ik} = peso sináptico do neurônio k

x = entrada da rede

X = fração molar do soluto na fase líquida

X_0 = fração molar do soluto no solvente à entrada da coluna

y = saída calculada pela rede

Y = fração molar do soluto na fase gasosa

Y_1 = fração molar do álcool no gás à saída da coluna de recuperação de etanol.

Y_{1SP} = *set point* da coluna de recuperação de etanol.

Y_{N+1} = fração molar do álcool no gás à entrada da coluna de recuperação de etanol.

Y_1' = fração molar de água no gás à saída da coluna de tratamento de CO_2

Y_{1SP}' = *set point* da coluna de tratamento de CO_2 .

Y_{N+1}' = fração molar de água no gás à entrada da coluna de tratamento de CO_2 .

Letas Gregas

α = termo de momentum

α' = parâmetro da função objetivo FO

β' = parâmetro da função objetivo FO

γ = parâmetros efetivamente utilizados pela rede

Δt = passo de integração

Δw = correção dos pesos sinápticos

η = taxa de aprendizagem

θ_d = atraso de transporte

λ = parâmetro do filtro

μ = escalar

ρ_n = massa específica molar média da mistura

τ_D = constante de tempo derivativo

τ_I = constante de tempo integral

τ_P = constante de tempo

φ = função de ativação

CAPÍTULO 1

INTRODUÇÃO

Durante a operação de uma determinada planta química, alguns objetivos específicos devem ser alcançados, para que esta se mostre viável. Entre eles, deve-se destacar a garantia de uma operação segura tanto para as pessoas diretamente ligadas à indústria, quanto para a sociedade que a cerca. Assim, devido ao padrão de qualidade exigido, mercado competitivo, constantes mudanças na economia, além do alto nível de integração entre as várias unidades de processamento de uma planta química, faz-se necessário a implementação de um robusto sistema de controle.

Segundo SALOMÃO e ONAGA (2006) nos últimos anos o aumento do preço do petróleo, principal produto da matriz energética global, tem levado o mundo a buscar alternativas, entre as quais, o álcool representa a principal promessa. Em 2005, o mercado brasileiro de etanol movimentou 6 bilhões de dólares. Em 2010, deve chegar a 15 bilhões. Ao contrário do movimento vivido pelas usinas nas décadas de 70 e 80, no qual o governo, através de subsídios, criou o Proálcool para incentivar a produção de etanol, atualmente, a perspectiva do aumento na produção de etanol se justifica pela carência do mercado, especialmente o internacional. A projeção é que nos próximos anos o mercado internacional de etanol aumente exponencialmente, pois, os custos na exploração das reservas de petróleo que ainda restam devem ser maiores, encarecendo ainda mais o produto final. A indústria automobilística mundial já aderiu em massa aos veículos bicomcombustíveis, que permitem o uso tanto do álcool como da gasolina. Para que o aumento do consumo de etanol se concretize é necessário que mais países, a exemplo do Brasil, adotem este combustível como alternativa. Nos Estados Unidos, cuja frota de carros representa 40% do total de veículos do planeta, há a expectativa de que o percentual de uso do etanol como combustível passe de 2,5% em 2006, para 30% em 2030, o que representaria um consumo de 230 bilhões de litros, cerca de 14 vezes a produção brasileira de álcool em 2006. A possibilidade de exportação de álcool vem despertando o interesse de outros países produtores de cana-de-açúcar, como a Jamaica, Nigéria e Índia. O aumento do número de países fornecedores deste combustível é importante, pois aumenta a segurança de abastecimento para os países consumidores. Apesar da concorrência, dificilmente algum país será capaz de tirar a liderança brasileira nesse campo, pelo menos em curto prazo. Esta superioridade é conseguida por uma junção de fatores, entre eles, o clima favorável, extensão territorial e reservas de água. Cada hectare de cana-de-açúcar plantada no Brasil

fornece 6800 litros de álcool, a um preço de 20 centavos de dólar/litro. Já nos Estados Unidos, o álcool feito de milho fornece 3200 litros/hectare a um custo de 47 centavos de dólar/litro. Esta diferença de custos se deve principalmente ao fato de que no Brasil as máquinas que fabricam o álcool são movidas à energia elétrica produzida pela queima do bagaço de cana, ao passo que nos Estados Unidos, o processo depende de energia gerada do carvão, óleo combustível ou do gás natural. No entanto, a supremacia do Brasil como provável exportador de álcool combustível não é definitiva, uma vez que o país possui debilidades, como a falta de investimentos em ciência e tecnologia.

Em matéria veiculada no site UOL em 11/04/08 foi relatada a superação do consumo da gasolina pelo álcool (anidro e hidratado) em fevereiro de 2008, quando foram consumidos 1,432 bilhão de litros de álcool contra 1,411 bilhão de litros de gasolina, uma diferença de 21 milhões. A informação foi fornecida pelo superintendente de Abastecimento da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), Edson Silva, o qual atribuiu o resultado à queda do preço do álcool destinado ao consumidor final, além do aumento nas vendas de carros do tipo bicomcombustível (flex). O consumo de álcool hidratado no primeiro bimestre de 2008 apresentou um crescimento de 56% em relação a igual período do ano passado, enquanto que o de gasolina cresceu apenas 2,9% e o do diesel, 11,5%. Ainda segundo Edson Silva, “esta é uma realidade que veio para ficar e com isso o país passa a consumir em maior escala de um combustível ecologicamente mais limpo e proveniente de fonte renovável”.

De acordo com ZAPAROLLI (2008), apesar da queda de rentabilidade do setor produtivo de etanol, vivenciada no início do ano de 2008, as perspectivas em longo prazo são promissoras. A rentabilidade caiu por causa do aumento da oferta de cana-de-açúcar, que cresceu em 58 milhões de toneladas apenas em 2007. Entretanto, a demanda de etanol, também cresce rapidamente. O consultor estima uma produção de etanol para a safra de 2013/2014 de 35 bilhões de litros, destes, 28 destinados ao mercado interno e os 7 bilhões de litros restantes visando a exportação. Outra movimentação do mercado de etanol, que contribui para as boas perspectivas, é o anúncio de empresas com relação à produção de etileno via etanol.

Durante o processo de produção de etanol por fermentação, acontecem perdas do produto por evaporação. Estas perdas variam com a concentração dos mostos, temperatura de fermentação, formato das dornas, entre outros fatores. A recuperação deste álcool pode

ser feita alimentando-se os vapores captados sobre as dornas a uma coluna de absorção de pratos. Para tanto, água é adicionada em contracorrente à mistura gasosa de álcool e dióxido de carbono (CO_2). O objetivo do sistema de controle consiste em assegurar que a composição do gás à saída da coluna permaneça o mais próximo possível da desejada (*set point*), sendo que para tanto, é efetuada a manipulação da vazão de solvente (água).

Este equipamento também é utilizado no tratamento do gás carbônico, um subproduto deste processo. Neste sentido, a corrente gasosa de CO_2 depois de ser separada do etanol, passa por um depurador para realizar a oxidação dos traços de matéria orgânica, e na sequência é alimentada a uma outra coluna de absorção de pratos destinada à retirada do vapor de água, carregado da primeira etapa de absorção. Neste caso o sistema de controle deve assegurar que a concentração de água no gás à saída da coluna seja mantida a um valor especificado (*set point*), sendo manipulada a vazão de solvente (ácido sulfúrico).

Entretanto, a coluna de absorção de pratos é um equipamento caracterizado pela sua não linearidade, e em consequência disso, técnicas convencionais de controle encontram dificuldades na garantia de um desempenho satisfatório.

Na busca de um sistema de controle compatível com a complexidade da maioria dos processos industriais, várias pesquisas têm sido elaboradas de acordo com o desenvolvimento de novas ferramentas e tecnologias. Neste sentido, o uso de redes neurais artificiais (RNAs) torna-se cada vez mais, uma opção atrativa, haja vista a atual ampliação da capacidade computacional. Devido às características não-lineares inerentes ao mapeamento entre camadas de RNAs *feedforward*, estas se caracterizam como ferramentas de modelamento bastante apropriadas para o modelamento e controle de sistemas. Ferramentas matemáticas disponíveis para o controle de sistemas não-lineares normalmente utilizam técnicas de linearização, transformando a tarefa de controle não-linear em pequenas tarefas de controle linear. Apesar de muitas vezes eficiente, esta abordagem não retrata a realidade dos sistemas físicos, podendo resultar em soluções subótimas. Devido à capacidade de modelar com fidelidade ações não-lineares, as RNAs são uma importante ferramenta para o controle de sistemas (BRAGA, 2000).

Em virtude da complexidade do sistema estudado, e conhecendo-se a capacidade de processamento das redes neurais, acredita-se que RNA, depois de devidamente treinada, seja capaz de determinar como deve ser feita a manipulação da vazão de solvente em uma

coluna de absorção de pratos. A avaliação desta metodologia de controle será realizada pela sua aplicação na recuperação do álcool perdido por evaporação em um processo de fermentação, assim como no tratamento do gás carbônico gerado neste processo, ainda que, existam atualmente usinas produtoras de etanol que não possuam qualquer equipamento destinado à recuperação desta quantidade de álcool e gás carbônico, ou mesmo, que utilizam apenas colunas de lavagem sem qualquer sistema de controle.

Depois de uma breve explanação sobre o problema da perda, por evaporação, de parte do etanol produzido durante o processo de fermentação, além da necessidade do tratamento do gás carbônico, assim como os requisitos para o sistema de controle para as colunas de absorção de pratos utilizadas, segue-se com a organização do presente trabalho.

No capítulo 2 é realizada uma revisão dos trabalhos disponíveis na literatura, que são relacionados à modelagem e controle de colunas de absorção. Além disso, são apresentados, de forma sucinta, conceitos teóricos sobre o algoritmo de treinamento utilizado para a rede neural. A partir deste levantamento bibliográfico foi possível direcionar a pesquisa no sentido de buscar soluções alternativas para o problema estudado.

Já no capítulo 3, é abordada a caracterização do sistema estudado, incluindo-se a definição das condições de operação, além do desenvolvimento da técnica de controle proposta.

No capítulo 4 são apresentados os resultados das simulações realizadas, demonstrando-se o desempenho da estratégia de controle proposta. Para avaliar o comportamento desta, efetuou-se a comparação com um controlador tradicional Proporcional Integral Derivativo (PID), sendo os parâmetros demonstrativos de desempenho, a integral do quadrado do erro (ISE), integral do erro absoluto (IAE) e a integral do erro absoluto ponderado pelo tempo (ITAE).

Finalmente, no capítulo 5, encontram-se as conclusões do presente trabalho, bem como as sugestões para trabalhos futuros.

1.1 OBJETIVOS

Tomando como base o levantamento bibliográfico realizado, pode-se perceber que o controle de uma coluna de absorção de pratos tem sido estudado por alguns pesquisadores. Entretanto, as técnicas empregadas até o momento não possuem a capacidade de processamento demonstrada pelas redes neurais artificiais (RNA's), as quais já foram aplicadas na modelagem desta operação unitária. Deste modo, os objetivos deste trabalho são o desenvolvimento e a utilização de um controlador *feedforward-feedback* baseado em modelo inverso de redes neurais para a manipulação das vazões de solvente das colunas de absorção empregadas no processo de produção de etanol por fermentação, sendo abordados os problemas regulatório e servo, assim como a influência das incertezas nos sensores no desempenho do controlador proposto.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

Neste capítulo serão apresentados conceitos relevantes sobre colunas de absorção, assim como redes neurais artificiais e o controlador convencional PID. Estes foram obtidos de trabalhos disponíveis na literatura, os quais representam os resultados de pesquisas realizadas anteriormente, sendo valiosos na verificação do que foi estudado até o momento e no direcionamento do presente trabalho, conforme apresentado no item Proposta da Tese, ao final deste mesmo capítulo.

2.2 COLUNAS DE ABSORÇÃO

A absorção gasosa é uma operação que envolve o contato entre as fases líquida e gasosa, sendo que um ou mais componentes presentes no gás, são absorvidos pelo líquido.

O campo de aplicação desta operação é muito vasto, encontrando espaço tanto na recuperação de produtos quanto no tratamento de efluentes. Desta forma, este assunto tem atraído a atenção de muitos pesquisadores, que visam o aprimoramento deste processo através de inovações no projeto de equipamentos, ou ainda, no desenvolvimento de novos sistemas de controle.

Seguindo esta linha de pesquisa, é possível encontrar vários trabalhos na literatura, entre os quais se destaca o elaborado por MAIA (1994), no qual é implementada a uma coluna de absorção de gases uma das técnicas de controle preditivo (Matriz Dinâmica de Controle (DMC)). A autora considerou o caso monovariável e sem restrições deste algoritmo de controle para que se pudesse fazer um estudo comparativo entre os desempenhos deste controlador preditivo (DMC) e um controlador convencional por retroalimentação (PI). Perturbações em degrau foram implementadas na composição do gás à entrada da coluna. Foram comparadas as respostas dos dois tipos de controladores (PI e DMC), tendo como variáveis controlada e manipulada, a composição do gás à saída da coluna, e a vazão de solvente, respectivamente. Ficou caracterizada a superioridade da estratégia de controle por matriz dinâmica, quando comparada à técnica convencional por

retro-alimentação. Com a utilização do DMC, a variável controlada apresentou-se com menor sobrelevação e com um rápido reestabelecimento do estado estacionário.

Outra proposta de controle para colunas de absorção bem sucedida foi apresentada por NAJIM (1995). Neste trabalho foi proposta a utilização do controle adaptativo em uma coluna de absorção com recheio. Este equipamento teve por finalidade a redução da concentração de CO_2 em uma mistura gasosa até um valor desejado. Para tanto, fez-se uso de uma solução aquosa de Dietanolamina (DEA). O modelo desenvolvido para simular a coluna foi baseado em balanço de massa, fenômenos de transporte e na reação química entre CO_2 e DEA, que ocorre na fase líquida. Este modelo consiste de um sistema não linear de três equações diferenciais parciais. A vazão de solvente e a concentração de CO_2 no topo da coluna foram, respectivamente, a variável manipulada e a controlada. A vazão de DEA foi controlada por uma válvula, sendo que a voltagem que alimenta o motor elétrico associado a essa válvula foi limitada, assegurando assim que a coluna não sofresse inundação. Os resultados obtidos asseguram a eficácia do modelo, assim como, a do sistema de controle proposto.

Já em 1997, SILVA realizou na primeira etapa de seu trabalho, o estudo dos perfis de concentração e fluxos mássicos ao longo de colunas recheadas de absorção com reação química, utilizando-se para tanto, as equações fundamentais de transferência de massa com o termo de reação química. Estas equações foram resolvidas numericamente, pelo método da colocação ortogonal em elementos finitos. Visando proceder a uma simulação mais rigorosa do processo, o autor utilizou o método das Características. Pelo fato deste necessitar do cálculo dos fluxos de transferência de massa em diversos pontos ao longo da coluna, dificultando assim, a sua utilização em conjunto com a resolução numérica das equações de transferência de massa, foi desenvolvido um modelo neural híbrido capaz de prever tais fluxos. Desta forma, o modelo utilizado nas simulações proporcionou a inclusão de importantes características hidrodinâmicas do processo. Na etapa final do trabalho, o autor avaliou o desempenho do controle preditivo com modelo linear (convolução) e não-linear (baseado em redes neurais artificiais). Os resultados demonstraram uma diferença de desempenho pouco significativa entre os dois controladores. Segundo SILVA, isto se deve em parte, a robustez proporcionada pelo controle preditivo, independentemente do modelo interno utilizado. Além disso, outro fator responsável pelo nivelamento de desempenho entre os controladores, seria a grande inércia

do sistema frente a variável manipulada. Desta forma, pela simplicidade de aplicação e o fornecimento de resultados razoáveis, a utilização do controle preditivo com modelo de convolução pode ser justificada.

Em 1998, RÓG e WILK apresentaram uma aplicação de redes neurais, tornando-se possível a simulação de uma coluna de absorção. Utilizando-se uma rede de arquitetura 14-14-10, treinada através do algoritmo da retropropagação com uso da regra delta generalizada, foi possível simular a coluna de absorção com sucesso. Os dados utilizados no processo de treinamento foram obtidos do modelo rigoroso da coluna, que também gerou um conjunto de dados adicional, destinado à comparação com os resultados fornecidos pela rede. Apesar de o sistema ser não linear e multivariável, a rede neural desenvolvida foi capaz de modelar e simulá-lo com sucesso.

No ano de 1999, PARTHASARATHY e colaboradores publicaram um artigo no qual apresentavam um modelo capaz de prever a inundação de uma coluna de absorção, sendo este utilizado como uma variável controlada em um controlador multivariável. Inicialmente, identificou-se um conjunto de variáveis representativas do processo de inundação. Diferentes tipos de modelos foram construídos e testados *off-line*, e devido a imprecisão do modelo linear, verificou-se que o processo apresentava não linearidades suficientes para justificar a utilização de um modelo baseado em redes neurais artificiais. Vários modelos baseados em redes neurais foram desenvolvidos e testados *on-line*, ficando caracterizado que a robustez e precisão destes, dependia tanto da qualidade, quanto da quantidade dos dados utilizados na etapa de treinamento. Desta forma, o modelo que apresentou os melhores resultados teve como variáveis de entrada a queda de pressão em uma determinada seção da coluna no instante atual e três minutos no passado, a pressão no topo da coluna, a vazão de gás purificado, nível de distúrbio na vazão de gás purificado, temperatura do gás a entrada da coluna e do solvente e a concentração de gás carbônico no gás alimentado a coluna. Assim, com uma estrutura composta por uma camada escondida com cinco neurônios, e utilizando a função de ativação tangente hiperbólica, o modelo desenvolvido foi capaz de prever, com sucesso, a queda de pressão em um instante de tempo de três minutos no futuro, fornecendo, portanto, informações valiosas ao sistema de controle central.

Dando continuidade ao trabalho de MAIA, PALÚ (2001) realizou um estudo do desempenho do Controle por Matriz Dinâmica (DMC), quando aplicado a uma coluna de

absorção, tanto para o caso monovariável (SISO), como para o caso multivariável (MIMO). Além de realizar o controle do sistema quando submetido a uma única perturbação no instante de tempo inicial, também se avaliou o desempenho do controlador para perturbações múltiplas. Estas perturbações, de magnitudes aleatórias, foram inseridas de forma periódica, visando aproximar o funcionamento da coluna de uma situação real. Em ambos os casos, comparou-se a resposta obtida pela estratégia de controle DMC com a resposta fornecida por um controlador convencional de retro-alimentação (PI), sendo a qualidade da primeira, muito superior a da segunda. Finalizando o trabalho, se propôs otimizar o funcionamento da coluna através da escolha adequada do(s) estágio(s) usado(s) para medir a composição do gás. Para quantificar o desempenho do sistema de controle foram propostos dois parâmetros: a quantidade de solvente gasta e a integral do quadrado do erro (ISE). Com o uso destes dois critérios foi possível estabelecer que a composição do gás deve ser medida no primeiro prato da coluna, assim, assegura-se o melhor desempenho do controlador.

Devido a dificuldade de previsão de estabilidade quando implementado um conjunto de parâmetros em um sistema de controle preditivo, NUNES (2003) e colaboradores apresentaram um método rigoroso de análise. A técnica empregada permite derivar expressões explícitas para as funções transferência. Assim, os pólos do sistema podem ser determinados encontrando as raízes de dois polinômios característicos, permitindo, portanto, a caracterização da estabilidade do sistema. Devido ao grande número de parâmetros a serem ajustados para o projeto de um controlador preditivo multivariável torna-se complexo. Uma estimativa equivocada destes parâmetros pode deixar algumas relações entrada-saída instáveis. Estas instabilidades podem ser “camufladas” pelas restrições físicas do processo que impedem que o sistema siga descontroladamente. No entanto, estas restrições fazem com que o sistema opere em condições sub-ótimas. Com a ferramenta de análise apresentada neste artigo, o projetista pode testar a estabilidade do sistema antes de implementar um conjunto de parâmetros. Para validar a técnica, o autor aplicou-a à uma coluna de absorção. Após a implementação de um primeiro conjunto de parâmetros, de acordo com o que fora detectado pela técnica, o sistema apresentou instabilidade. Já depois da implementação de um segundo conjunto de parâmetros, o sistema mostrou-se estável, conforme previsto pela análise.

MELEIRO et al (2005) fez uso de redes neurais artificiais para controlar a etapa de fermentação, em um processo de produção de álcool. O modelo interno utilizado no controlador preditivo não-linear foi composto por duas redes do tipo *Functional Link Networks* (FLN). A estrutura testada possui a vantagem de o treinamento ser rápido e da garantia de convergência. O desempenho do controlador proposto, avaliado para o problema servo e regulatório, produziu resultados satisfatórios.

2.2.1 MODELO DINÂMICO DA COLUNA (MAIA, 1994)

O modelo matemático para uma coluna de absorção de N estágios, empregado neste trabalho foi obtido por meio de balanços de massa globais para cada estágio n, balanços de massa globais para o componente que é absorvido em cada estágio n, relação de equilíbrio, equação de Francis, além de algumas simplificações, sendo elas:

1. Apenas um componente é transferido de uma fase para outra.
2. A absorção é considerada isotérmica.
3. Considera-se cada estágio como ideal.
4. A transferência de soluto entre as fases não altera as vazões, nem do gás e nem do líquido.
5. A pressão é constante ao longo da coluna.
6. Assume-se que nenhuma quantidade de gás fica retida entre os estágios.

A numeração dos pratos da coluna de absorção é feita de forma descendente. Deste modo, a coluna é alimentada com o gás no N-ésimo prato, e com o solvente no primeiro. A seguir apresenta-se (Figura 2.1) um esquema da coluna de absorção, com suas correntes de entrada e saída, bem como suas respectivas frações molares. Além disso, é apresentado o estágio genérico “n” em detalhe.





Figura 2.1 – Esquema da coluna de absorção

Onde:

X = Fração molar do soluto na fase líquida.

Y = Fração molar do soluto na fase gasosa.

L = Vazão de solvente.

G = Vazão de gás.

N = Número de estágios.

Visando obter equações que forneçam suporte para a simulação da dinâmica da coluna de absorção, tem-se:

Balanço de massa global para o estágio n :

$$\frac{dM_n}{dt} = L_{n-1} - L_n \quad (2.01)$$

Balanço de massa global para o componente que é absorvido no estágio n :

$$\frac{d(M_n X_n)}{dt} = L_{n-1} X_{n-1} - L_n X_n + G(Y_{n+1} - Y_n) \quad (2.02)$$

Onde:

M = Massa molar de líquido contida em cada estágio.

A relação de equilíbrio líquido-vapor utilizada neste trabalho é da forma:

$$Y_n = m \cdot X_n \quad (2.03)$$

Onde m é uma constante.

Para obter a massa específica molar média de uma mistura binária (componentes A e B) faz-se uso da seguinte expressão:

$$\rho_{média} = \rho_A X_A + \rho_B (1 - X_A) \quad (2.04)$$

A retenção de líquido no prato é dada pela Equação de Francis:

$$M_n = A_p \rho_n \left[h_v + c \left(\frac{L_n}{\rho_n L_w} \right)^{2/3} \right] \quad (2.05)$$

na qual:

ρ_n = Massa específica molar média da mistura (moles/cm³)

A_p = Área do prato (cm²)

c = Constante (cm^{-1/3}s^{2/3})

h_v = Altura do vertedouro (cm)

L_w = Comprimento do vertedouro (cm)

Para se obter a vazão de líquido que deixa cada prato (L_n), basta isolar esta variável na Equação (2.05):

$$L_n = \rho_n L_w \left[\frac{1}{c} \left(\frac{M_n}{A_p \rho_n} - h_v \right) \right]^{3/2} \quad (2.06)$$

Além das equações apresentadas até então, para que se possa realizar a simulação da coluna de absorção de pratos, as Equações diferenciais ordinárias 2.01 e 2.02 devem ser integradas numericamente. Neste trabalho, o método escolhido para realizar tal tarefa foi o de Euler explícito, pois segundo LUYBEN (1990), este método, dentre as várias opções disponíveis na literatura, possui a vantagem de ser eficaz e facilmente programável, desde

que o passo de integração utilizado seja adequado (quanto menor o valor deste parâmetro, mais preciso será o resultado da integração, sendo o limite máximo recomendado o valor correspondente a duas vezes a constante de tempo do processo).

As Equações 2.01 e 2.02, depois de serem integradas passam a apresentar a seguinte forma:

$$M_n|_{t+\Delta t} = M_n|_t + \left[\left(\frac{d}{dt}(M_n) \right) \Big|_t \right] \Delta t \quad (2.07)$$

$$(M_n X_n)|_{t+\Delta t} = (M_n X_n)|_t + \left[\left(\frac{d}{dt}((M_n X_n)) \right) \Big|_t \right] \Delta t \quad (2.08)$$

Onde:

Δt = Passo de integração.

De posse das Equações 2.01 a 2.08 é possível simular o comportamento dinâmico da coluna. Assim sendo, na Figura 2.2 é apresentado um fluxograma contendo todas as etapas deste processo.

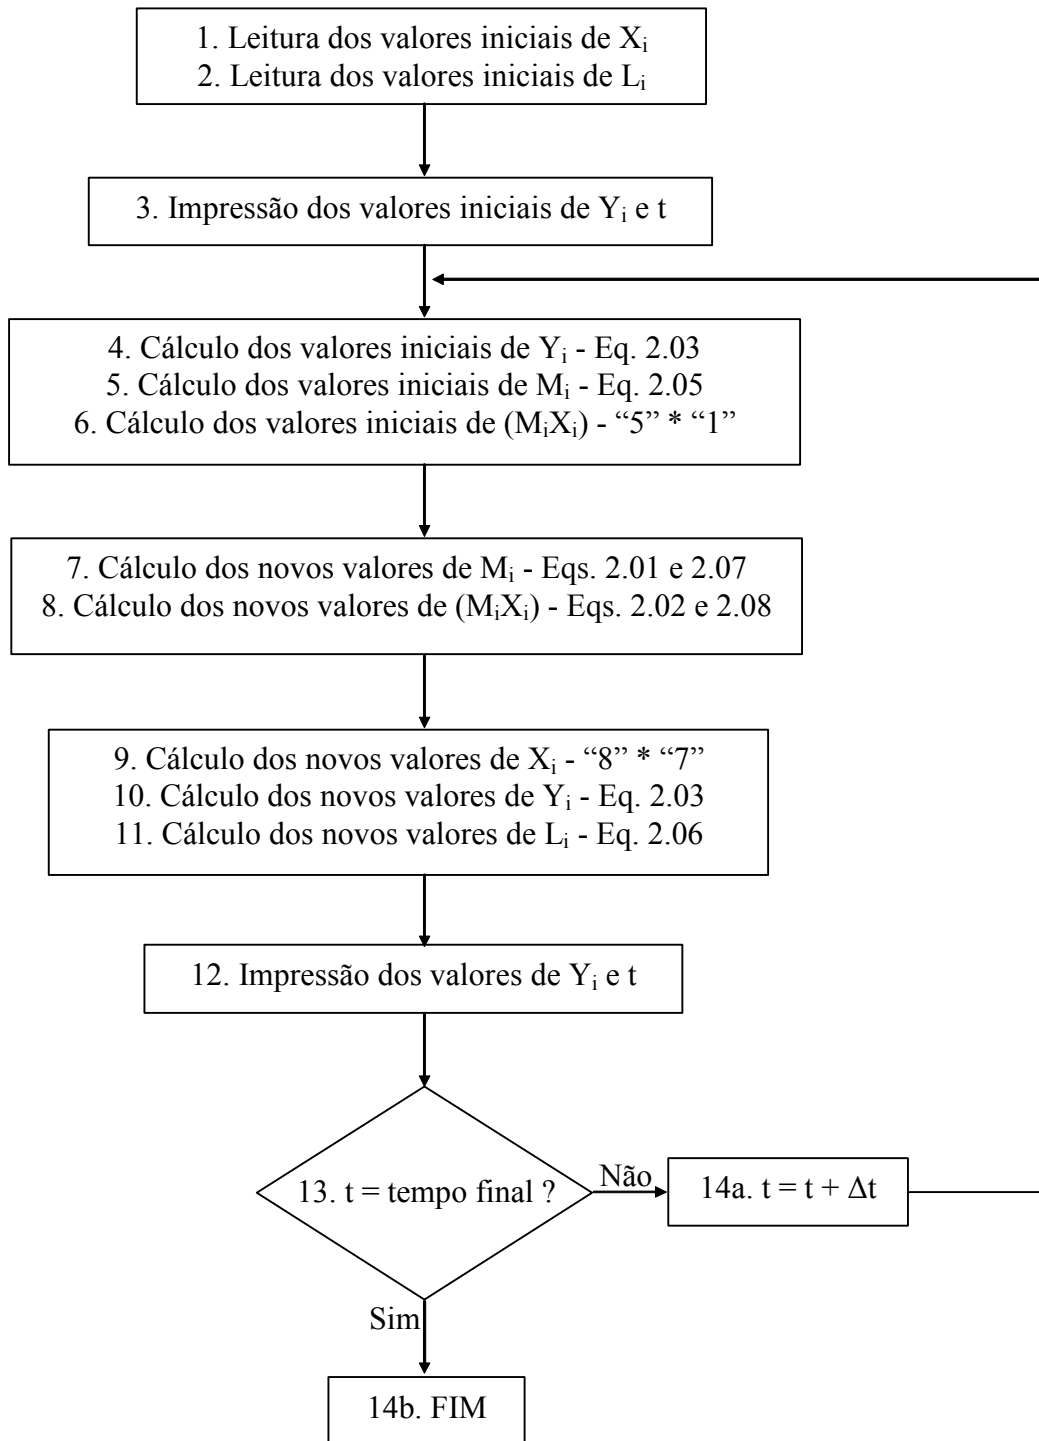


Figura 2.2 – Fluxograma do processo de simulação da coluna de absorção

2.3 REDES NEURAIS ARTIFICIAIS

2.3.1 TREINAMENTO

A utilização da rede neural artificial para um determinado fim está diretamente vinculada à eficiência com que esta é capaz de fornecer respostas próximas, o suficiente, dos dados de saída reais. Para tanto, o neurônio artificial deve ser capaz de aprender uma determinada tarefa.

Na fase de aprendizagem, a rede extrai informações relevantes de padrões de informação apresentados a ela, criando assim uma representação própria do problema. Nesta etapa, portanto, há o ajuste dos parâmetros da rede, que são caracterizados pelos pesos das conexões entre as unidades de processamento. Deste modo, ao final do processo de treinamento, a rede terá adquirido conhecimento sobre o ambiente em que está operando, sendo este, “armazenado” em seus parâmetros.

Existem vários métodos para realizar o treinamento de redes neurais artificiais, no entanto, quando estas são aplicadas na modelagem de processos, utiliza-se o aprendizado supervisionado.

O objetivo deste método é o de ajustar os parâmetros da rede, de modo a estabelecer uma ligação entre os pares de entrada e saída fornecidos por um supervisor externo.

O supervisor é responsável por direcionar o processo de treinamento. Para tanto, a resposta calculada pela rede é comparada a resposta desejada, fornecida pelo próprio supervisor, a qual constitui uma ação ótima a ser tomada pela rede. A diferença existente entre estes dois valores representa o erro gerado pelo cálculo da rede, o qual deve ser minimizado através do ajuste dos pesos das conexões.

A minimização do erro é incremental, pois a cada etapa de treinamento, isto é, a cada resposta gerada pela rede e, conseqüentemente, a cada atualização do valor do erro, são efetuados pequenos ajustes nos pesos das conexões.

A implementação do aprendizado supervisionado pode ser feita tanto *off-line* quanto *on-line*, sendo que no primeiro caso, os dados do conjunto de treinamento não

mudam, e caso seja necessário a inclusão de novos dados, um outro banco de dados destinado ao treinamento deve ser elaborado, contendo os dados antigos acrescido dos novos. Já para o segundo caso, a rede opera em constante processo de adaptação, sendo atualizada continuamente.

2.3.2 PERCEPTRON

A função básica do neurônio biológico é somar todas as suas entradas, e produzir uma saída se esta soma for maior que um determinado valor, conhecido como valor limiar. As entradas chegam até os neurônios ao longo dos dendritos, os quais são conectados com as saídas por meio de outros neurônios através de junções chamadas sinapses. Estas junções alteram a eficiência com que o sinal é transmitido; algumas sinapses são boas junções, e passam um forte sinal adiante, enquanto que outras, muito ruins, permitem a passagem de um sinal fraco. O corpo celular recebe todas estas entradas, e dispara, se o total de entradas exceder o valor limiar. (BEALE, 1990).

Em 1943, MCCULLOCH e PITTS deram ênfase à modelagem de um neurônio biológico e sua capacidade computacional, empregada na execução de funções booleanas. O modelo proposto (denominado, nodo MCP) substituíam os dendritos por entradas, e estabelecia que as ligações destas com o corpo celular artificial, seriam realizadas através de elementos chamados de pesos (fatores que multiplicados às suas respectivas entradas, simulariam as sinapses). Deste modo, uma sinapse de maior eficiência, ou seja, que transmite um sinal forte, seria representada pela associação de um peso de maior valor à sua entrada. Além disso, os estímulos captados pelas entradas seriam processados em uma função de soma, sendo que o resultado desta, seria alimentado à uma função de ativação, responsável pela produção da saída.

Apesar de muito importante, o trabalho de MCCULLOCH e PITTS (1943) não incluía técnicas de aprendizagem para o modelo desenvolvido. Mais tarde, em 1958, esta lacuna seria preenchida pelo modelo proposto por Frank Rosenblatt, denominado perceptron, que era composto por uma estrutura de rede, tendo como unidades básicas nodos MCP, e por um algoritmo de treinamento.

A Figura 2.3 demonstra a topologia do perceptron, para uma única saída.

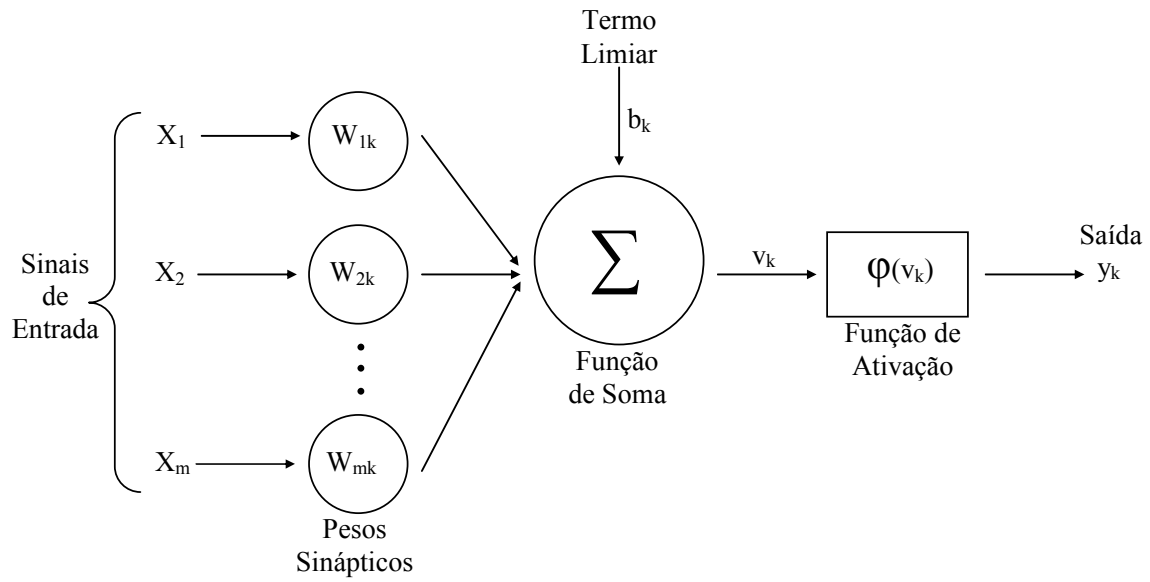


Figura 2.3 – Topologia de um perceptron simples

O modelo neural anteriormente descrito também inclui o termo limiar, denotado por b_k . Este termo possui a função de causar um decréscimo na entrada da função transferência, v_k .

Desta forma, pra o neurônio k , temos:

$$v_k = \sum_{j=1}^N w_{jk} x_j + b_k \quad (2.09)$$

$$y_k = \varphi(v_k) \quad (2.10)$$

Onde:

x_1, x_2, \dots, x_N = Sinais de entrada.

$w_{1k}, w_{2k}, \dots, w_{Nk}$ = Pesos sinápticos do neurônio k .

b_k = Termo Limiar.

$\varphi(v_k)$ = Função de ativação.

v_k = Entrada da função de ativação.

O termo limiar, b_k , é um parâmetro externo ao neurônio k . Sendo assim, este termo pode ser incluído no somatório da Equação 2.09, na forma de uma entrada adicional, caracterizada por $x_0 = +1$, além do peso sináptico a ela associado $w_{k0} = b_k$. Assim, a equação 2.09 pode ser escrita da seguinte forma:

$$v_k = \sum_{j=0}^N w_{jk} x_j \quad (2.11)$$

A função de ativação, denotada por φ , é responsável por fornecer a saída do neurônio. Para o perceptron, a função de ativação utilizada, é a função degrau (Equação 2.12).

$$\varphi(v_k) = \begin{cases} y_k = 1 & \text{se } v_k \geq 0 \\ y_k = 0 & \text{se } v_k < 0 \end{cases} \quad (2.12)$$

2.3.3 MULTICAMADAS DE NEURÔNIOS ARTIFICIAIS

Para efetuar a modelagem de sistemas físicos faz-se necessário uma rede neural composta por multicamadas, semelhante à arquitetura demonstrada na Figura 2.4.




Figura 2.4 – Arquitetura de uma rede neural artificial

A arquitetura apresentada na Figura 2.4 é um exemplo de rede neural *feedforward* completamente conectada, ou seja, cada neurônio em uma determinada camada está conectado aos demais da camada seguinte.

Através da rede passam dois tipos de sinais, sendo o primeiro deles chamado de sinal função. Este sinal é recebido pelos nódulos da camada de entrada na forma de estímulos gerados pelo ambiente externo e propaga-se ao longo da rede, sendo processado em cada neurônio intermediário na forma de uma função das entradas, ponderadas pelos pesos à elas associados, até que emergindo dos nódulos da camada de saída, produz a resposta da rede. Já o segundo sinal, é constituído de uma função erro, que se propaga no sentido oposto à rede, sendo útil para o algoritmo de aprendizagem *Backpropagation*.

2.3.3.1 ALGORITMO DA RETROPROPAGAÇÃO (OU *BACKPROPAGATION*)

O algoritmo da retropropagação, também conhecido como regra delta generalizada foi proposto por RUMELHART e MCCLELLAND em 1986. Nele, o aprendizado é efetuado com base no erro incluso na resposta fornecida pela rede, o que significa que a diferença entre a resposta atual da simulação e a desejada deve ser minimizada, sendo

necessário, portanto, o ajuste dos pesos sinápticos associados às entradas dos neurônios. Assim, o erro calculado na camada de saída é retropropagado às camadas anteriores, servindo de base para a modificação de todos os pesos, até que a resposta obtida pela rede seja satisfatória.

Matematicamente, o erro na iteração n , correspondente à análise do n -ésimo par de exemplos (dados de entrada – saída) apresentados à rede, é a diferença entre a resposta atual, $y_j(n)$, e a desejada, $d_j(n)$, conforme Equação 2.13.

$$e_j(n) = d_j(n) - y_j(n) \quad (2.13)$$

O erro calculado em relação à todos os M nódulos de saída pode ser obtido da seguinte maneira (Equação 2.14).

$$E(n) = \frac{1}{2} \sum_{j=1}^M e_j^2(n) \quad (2.14)$$

A função objetivo, que se deseja minimizar é dada pela Equação 2.15.

$$\bar{E} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (2.15)$$

Onde N representa o número total de pares apresentados.

Admitindo-se que o neurônio j seja alimentado pelos sinais função $y_i(n)$ emitidos pelos nódulos i da camada anterior, sendo cada sinal associado à um peso sináptico $w_{ij}(n)$, o nível de atividade do nódulo j pode ser expresso pela Equação 2.16.

$$v_j(n) = \sum_{i=0}^I w_{ij}(n) y_i(n) \quad (2.16)$$

Onde I é o número total de nódulos que enviam sinais função ao nódulo j , e $w_{0j}(n)$ corresponde ao limiar de j .

Desta forma, a resposta produzida pela rede é apresentada na Equação 2.17.

$$y_j(n) = \varphi(v_j(n)) \quad (2.17)$$

Onde φ é uma função contínua e diferenciável, como por exemplo uma função sigmoidal.

O algoritmo de retropropagação baseia-se no ajuste dos pesos sinápticos proporcionalmente à diminuição do erro, $E(n)$. Assim, através da regra da cadeia pode-se escrever a Equação 2.18.

$$\frac{\partial E(n)}{\partial w_{ij}(n)} = \left(\frac{\partial E(n)}{\partial e_j(n)} \right) \left(\frac{\partial e_j(n)}{\partial y_j(n)} \right) \left(\frac{\partial y_j(n)}{\partial v_j(n)} \right) \left(\frac{\partial v_j(n)}{\partial w_{ij}(n)} \right) \quad (2.18)$$

Diferenciando a Equação 2.14 em relação à $e_j(n)$, têm-se:

$$\left(\frac{\partial E(n)}{\partial e_j(n)} \right) = e_j(n) \quad (2.19)$$

Diferenciando a Equação 2.13 com relação à $y_j(n)$, têm-se:

$$\left(\frac{\partial e_j(n)}{\partial y_j(n)} \right) = -1 \quad (2.20)$$

O terceiro termo da Equação 2.19 é obtido por meio da diferenciação da Equação 2.17 em relação à $v_j(n)$.

$$\left(\frac{\partial y_j(n)}{\partial v_j(n)} \right) = \varphi'(v_j(n)) \quad (2.21)$$

Finalmente, diferenciando a Equação 2.16 em relação à $w_{ij}(n)$, têm-se:

$$\left(\frac{\partial v_j(n)}{\partial w_{ij}(n)} \right) = y_i(n) \quad (2.22)$$

Substituindo-se as Equações 2.19, 2.20, 2.21 e 2.22 na Equação 2.18, obtém-se:

$$\left(\frac{\partial E_j(n)}{\partial w_{ij}(n)} \right) = -e_j(n) \varphi'(v_j(n)) y_i(n) \quad (2.23)$$

A correção dos pesos sinápticos, $\Delta w_{ij}(n)$ é obtida por meio da regra delta.

$$\Delta w_{ij}(n) = -\eta \left(\frac{\partial E_j(n)}{\partial w_{ij}(n)} \right) \quad (2.24)$$

Onde η é o parâmetro da taxa de aprendizagem, e o uso do sinal negativo deve-se ao fato do aprendizado ser efetuado no sentido do decréscimo do gradiente do erro.

Substituindo-se a Equação 2.23 na Equação 2.24, têm-se:

$$\Delta w_{ij}(n) = \eta \delta_i(n) y_j(n) \quad (2.25)$$

Onde:

$$\delta_i(n) = -\frac{\partial E(n)}{\partial v_j(n)} = e_j(n) \varphi_j'(v_j(n)) \quad (2.26)$$

Observando-se a Equação 2.25 pode-se concluir que a dificuldade de se definir o ajuste dos pesos está concentrada no cálculo do erro, $e_j(n)$.

Se j é um nóculo de saída, então o cálculo do erro é extremamente simples (Equação 2.06), pois a resposta desejada é conhecida, o que não acontece quando o neurônio j está localizado em uma camada oculta. Neste caso, o erro deve ser determinado a partir de sinais provenientes dos neurônios da camada seguinte que estão conectados ao nóculo j .

Aplicando a regra da cadeia na Equação 2.26, têm-se:

$$\delta_i(n) = - \left(\frac{\partial E(n)}{\partial y_j(n)} \right) \left(\frac{\partial y_j(n)}{\partial v_j(n)} \right) = - \left(\frac{\partial E(n)}{\partial y_j(n)} \right) \phi_j'(v_j(n)) \quad (2.27)$$

Considerando um neurônio k, integrante da camada de saída, conforme demonstrado na Figura 2.5, pode-se proceder o cálculo do erro segundo a Equação 2.28.




Figura 2.5 – Detalhe da conexão entre os neurônios “j” e “k”

$$E(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (2.28)$$

Diferenciando a Equação 2.28 em relação à $y_j(n)$, têm-se:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \left(\frac{\partial e_k(n)}{\partial y_j(n)} \right) \quad (2.29)$$

Aplicando a regra da cadeia à Equação 2.29, têm-se:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \left(\frac{\partial e_k(n)}{\partial v_j(n)} \right) \left(\frac{\partial v_j(n)}{\partial y_j(n)} \right) \quad (2.30)$$

Como o erro na última camada pode ser calculado com base na resposta desejada, para o nóculo k, têm-se:

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi_k(v_k(n)) \quad (2.31)$$

Diferenciando a Equação 2.31 em relação à $v_k(n)$, têm-se:

$$\left(\frac{\partial e_k(n)}{\partial v_j(n)} \right) = -\varphi_k'(v_k(n)) \quad (2.32)$$

O nível de atividade para o nóculo k é dado pela Equação 2.33.

$$v_k(n) = \sum_{j=0}^m w_{jk}(n) y_j(n) \quad (2.33)$$

Diferenciando a Equação 2.33 em relação à $y_j(n)$ têm-se:

$$\left(\frac{\partial v_k(n)}{\partial y_j(n)} \right) = w_{jk}(n) \quad (2.34)$$

Substituindo-se as Equações 2.32 e 2.34 na Equação 2.29, obtém-se a relação desejada.

$$\frac{\partial E(n)}{\partial y_j(n)} = -\sum_k e_k(n) \varphi'_k(v_k(n)) w_{jk}(n) = -\sum_k \delta_k(n) w_{jk}(n) \quad (2.35)$$

Finalmente substituindo-se a Equação 2.35 na Equação 2.27, obtém-se a fórmula da retropropagação para $\delta_j(n)$, no caso em que j é um nóculo oculto.

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{jk}(n) \quad (2.36)$$

Neste momento já é possível determinar o ajuste dos pesos sinápticos vinculados as conexões com o neurônio j (Equação 2.25), seja ele integrante de uma camada intermediária ou da camada de saída.

A taxa de aprendizagem (η), presente na Equação 2.25, constitui um importante parâmetro, pois estabelece uma relação entre a velocidade de convergência e a probabilidade de instabilidade no processo de aprendizagem. Caso η assumia valores muito pequenos, as mudanças nos pesos sinápticos também serão muito suaves, acarretando assim, um aumento do número de iterações requeridas pelo treinamento. Entretanto, se η for muito grande, as mudanças serão bruscas, provocando instabilidades no processo de aprendizagem.

Para facilitar a obtenção do equilíbrio entre a velocidade de convergência e a estabilidade do treinamento, RUMELHART e MCCLELLAND (1986) propôs a inclusão de mais um termo à Equação 2.25.

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_j(n) + \alpha \Delta w_{ij}(n-1) \quad (2.37)$$

Onde:

α = Termo de momentum.

2.3.3.2 ALGORITMO DE LEVENBERG-MARQUARDT COM REGULARIZAÇÃO BAYESIANA

Segundo DEMUTH e BEALE (2002), pelo fato do algoritmo *backpropagation* apresentar um processo de convergência lento, foram desenvolvidos métodos alternativos que convergem a uma velocidade maior que aquele. Dentre estes métodos de otimização para treinamento de redes neurais, se destaca o algoritmo de Levenberg-Marquardt.

De acordo com KERNANI e colaboradores (2005), este algoritmo representa a “ponte” entre o método Gauss-Newton e o de gradiente descendente. O primeiro método possui uma velocidade de convergência muito alta, devida a suas propriedades quadráticas. No entanto, há uma dependência elevada dos valores iniciais dos pesos e *bias*, cujas estimativas podem ser muito difíceis em uma aplicação em um sistema real. Já o segundo método citado, apresenta uma maior precisão quando a região próxima ao mínimo da função objetivo é alcançada. Entretanto, sua velocidade de convergência é baixa, pois minimiza a função objetivo de maneira linear. Combinando os atributos positivos dos dois métodos, o algoritmo de Levenberg-Marquardt faz uso de uma técnica de otimização híbrida, a qual pode ser aplicada no tratamento de muitos problemas reais.

A equação de iteração para este método pode ser escrita da seguinte forma:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (2.38)$$

Onde:

J = Matriz Jacobiana, a qual contém as derivadas primeiras dos erros da rede com relação aos pesos e *bias*.

$H = J^T J$ = Aproximação da matriz de Hess, a qual contém as derivadas segundas dos erros da rede com relação aos pesos e *bias*.

O valor do escalar μ define qual método de otimização prevalece (Gauss-Newton ou gradiente descendente). Quando μ assume um valor elevado o método utilizado é o gradiente descendente. Por outro lado, ao diminuir μ , a técnica empregada aproxima-se do método de Gauss-Newton. Assim, a manipulação de μ visa usufruir das vantagens dos dois métodos, minimizando o efeito das suas desvantagens. Quando um passo resultaria em um acréscimo da função objetivo, μ é multiplicado por uma constante $\mu' > 1$, para direcionar o algoritmo ao método do gradiente descendente, e assim, obter maior estabilidade. Em contrapartida, quando um passo resultaria em um decréscimo na função objetivo, μ é multiplicado por $1/\mu'$, para direcionar o algoritmo ao método de Gauss-Newton, aumentando assim, a velocidade de convergência (KERNANI, 2005).

Além da minimização da função objetivo, o processo de treinamento tem como meta, conferir à rede a capacidade de generalização. Entretanto, o fato de apresentar um erro muito pequeno na etapa de treinamento não implica em uma boa generalização posterior, sendo este problema conhecido como sobre-ajuste. A rede memorizou os exemplos de treinamento, mas não aprendeu generalizar em situações novas (DEMUTH e BEALE, 2002).

Sendo assim, no caso de sobre-ajuste, a rede pode estar sobreparametrizada, ou seja, a rede possui um número excessivo de parâmetros (pesos), necessitando ser redimensionada. O objetivo do treinamento deve ser então o de encontrar o número de parâmetros ideal. No entanto, estimar o número de parâmetros é uma tarefa árdua que requer conhecimento sobre a complexidade do problema. Este conhecimento normalmente

não está disponível, principalmente tratando-se de problemas multidimensionais, pois muitas vezes é este conhecimento que se deseja obter por meio do processo de modelagem (BRAGA, 2000).

Segundo DEMUTH e BEALE (2002) uma opção para melhorar a generalização, e evitar o sobre-ajuste, é a modificação da função objetivo. Neste sentido, o algoritmo de Regularização Bayesiana prevê a substituição da média dos erros quadrados da rede (expressão normalmente utilizada como função objetivo) pela Equação 2.39.

$$FO = \alpha' SSE + \beta' SSW \quad (2.39)$$

Onde:

FO = Função objetivo.

SSE = Soma dos quadrados dos erros.

SSW = Soma dos quadrados dos pesos.

α' e β' = Parâmetros da função objetivo.

Os parâmetros α' e β' são obtidos através da utilização de técnicas estatísticas, com a estrutura de *Bayes*. Como a técnica de Regularização Bayesiana requer o cálculo da matriz de Hess, o algoritmo de treinamento associado à regularização é o de Levenberg-Marquardt (FORESSE e HAGAN, 1997).

Uma das vantagens do algoritmo de Levenberg-Marquardt com Regularização Bayesiana é o fornecimento do valor de γ , parâmetros da rede que estão efetivamente sendo utilizados. Esta medida pode ser empregada no dimensionamento da rede, pois de acordo com FORESSE e HAGAN (1997), caso o valor de γ seja muito próximo do número total de parâmetros (N'), então se deve aumentar o tamanho da rede (aumentando o número de neurônios na camada intermediária), pois a rede pode não ser grande o suficiente para tratar o problema em questão. Este procedimento deve ser repetido até que γ se torne constante, não importando quão grande seja N' .

2.4 CONTROLADOR PROPORCIONAL INTEGRAL DERIVATIVO (PID)

A lei de controle utilizada para o PID digital pode ser escrita da seguinte forma:

$$L_0(kTa) = L_0(kTa - Ta) + K_c e(kTa) + \frac{Ta}{\tau_I} \sum_{i=0}^k e(iTa) + \tau_D \left(\frac{e(iTa) - e(iTa - 1)}{Ta} \right) \quad (2.40)$$

A Equação 2.40 é conhecida como forma posição, pois a cada instante de amostragem, a lei de controle fornece diretamente, o valor atual (posição) da saída do controlador (OGUNNAIKE e RAY, 1994).

A utilização do controle digital deve ser precedida por uma análise de estabilidade. No entanto, dependendo da complexidade do processo, esta análise pode se tornar muito difícil de ser concretizada. Aproximações para processos mais simples, como os de primeira e segunda ordem, podem ser realizadas, entretanto, perde-se na precisão dos resultados. Sendo assim, simulações do processo, sob a ação do controle digital, podem ser efetuadas para que se avalie o comportamento deste.

2.5 PROPOSTA DA TESE

Com base no levantamento bibliográfico realizado, foi possível perceber que o controle de uma coluna de absorção de pratos tem sido alvo de estudos de alguns pesquisadores. No entanto, as técnicas empregadas até o momento não possuem a capacidade de processamento demonstrada pelas redes neurais artificiais (RNA's), as quais já foram aplicadas na modelagem desta operação unitária. Sendo assim, o presente trabalho propõe o desenvolvimento e a utilização de um controlador *feedforward-feedback* baseado em modelo inverso de redes neurais para manipulação das vazões de solvente das colunas de absorção empregadas no processo produtivo de etanol por fermentação. Comparações

serão realizadas em relação à aplicação de um controlador convencional PID. Também será avaliada a influência das incertezas nos sensores, no desempenho do sistema de controle proposto.

CAPÍTULO 3

**ESTRATÉGIA DE CONTROLE PARA
COLUNA DE ABSORÇÃO DE PRATOS**

3.1 INTRODUÇÃO

Neste capítulo o sistema estudado é mais bem detalhado, assim como a estratégia de controle via redes neurais artificiais proposta, incluindo o procedimento a ser aplicado para sua implementação. Também é mencionado o controlador utilizado para a comparação de resultados, além do procedimento utilizado para a sintonia de seus parâmetros. Na sequência é então descrita a metodologia empregada para a inserção das incertezas nos sensores, e por fim, são apresentados os critérios de desempenho utilizados.

3.2 SISTEMA ESTUDADO

O etanol perdido por evaporação é captado nos tanques de fermentação e direcionado a primeira coluna de absorção do processo, composta de 9 estágios e operando a 40°C e 1 atm. Esta coluna deve processar uma vazão de 61,9 mols/s da mistura gasosa composta pelo gás carbônico e etanol, cuja concentração deve ser reduzida de 10000 ppm para 200 ppm (SHERWOOD, 1975). Para tanto, água é alimentada em contracorrente, sendo que esta, por ser proveniente de uma etapa posterior de destilação contém 100 ppm de álcool. O objetivo do sistema de controle consiste em assegurar que a composição do gás à saída da coluna permaneça o mais próximo possível da desejada (*set point*), manipulando-se a vazão de água empregada na coluna. Segundo SHERWOOD (1975) para a faixa de concentração trabalhada, a relação de equilíbrio pode ser aproximada pela equação $Y = 1,0682X$, onde Y e X são, respectivamente, as frações molares de etanol na fase gasosa e líquida.

Para as condições de operação descritas anteriormente, considerando-se as concentrações de álcool na corrente gasosa à entrada da coluna sem qualquer perturbação e a concentração de álcool no gás à saída desta como sendo igual ao *set point*, o etanol deve ser recuperado a uma vazão de 100,46 kg/h.

Segundo SHREVE (1997) depois de passar pela coluna de absorção descrita anteriormente, a corrente de CO₂, agora com apenas traços de álcool, porém com certa quantidade de vapor de água arrastada da primeira etapa, é direcionada a um depurador, o

qual é responsável pela oxidação das impurezas orgânicas pelo uso de $K_2Cr_2O_7$. Em seguida, a mistura gasosa livre de álcool, mas com uma concentração de 20000 ppm de água, é encaminhada à segunda coluna de absorção do processo. Esta coluna, composta por 7 estágios, operando a 30°C e 1 atm, processa 60,3 mols/s de mistura gasosa (CO_2 + água), fazendo uso de ácido sulfúrico para promover a absorção da água e completar a oxidação de alguma impureza orgânica, permitindo assim, que a concentração de água na corrente gasosa à saída da coluna fique em torno de 300 ppm, resultando, para estas condições de operação, no tratamento de cerca de 9300 kg/h de CO_2 . Novamente, o sistema de controle realiza a manipulação da vazão de solvente que é empregada na coluna. Os dados de equilíbrio líquido-vapor utilizados são demonstrados na Figura 3.1.




Figura 3.1 – Dados de equilíbrio líquido-vapor para a água residual na coluna de tratamento de CO_2

Para uma melhor visualização do sistema estudado, na Figura 3.2 é apresentado um esquema geral. Nesta, é possível observar as correntes de entrada e saída das colunas de absorção estudadas, assim como as variáveis de entrada dos controladores neurais e as respectivas ações de controle.

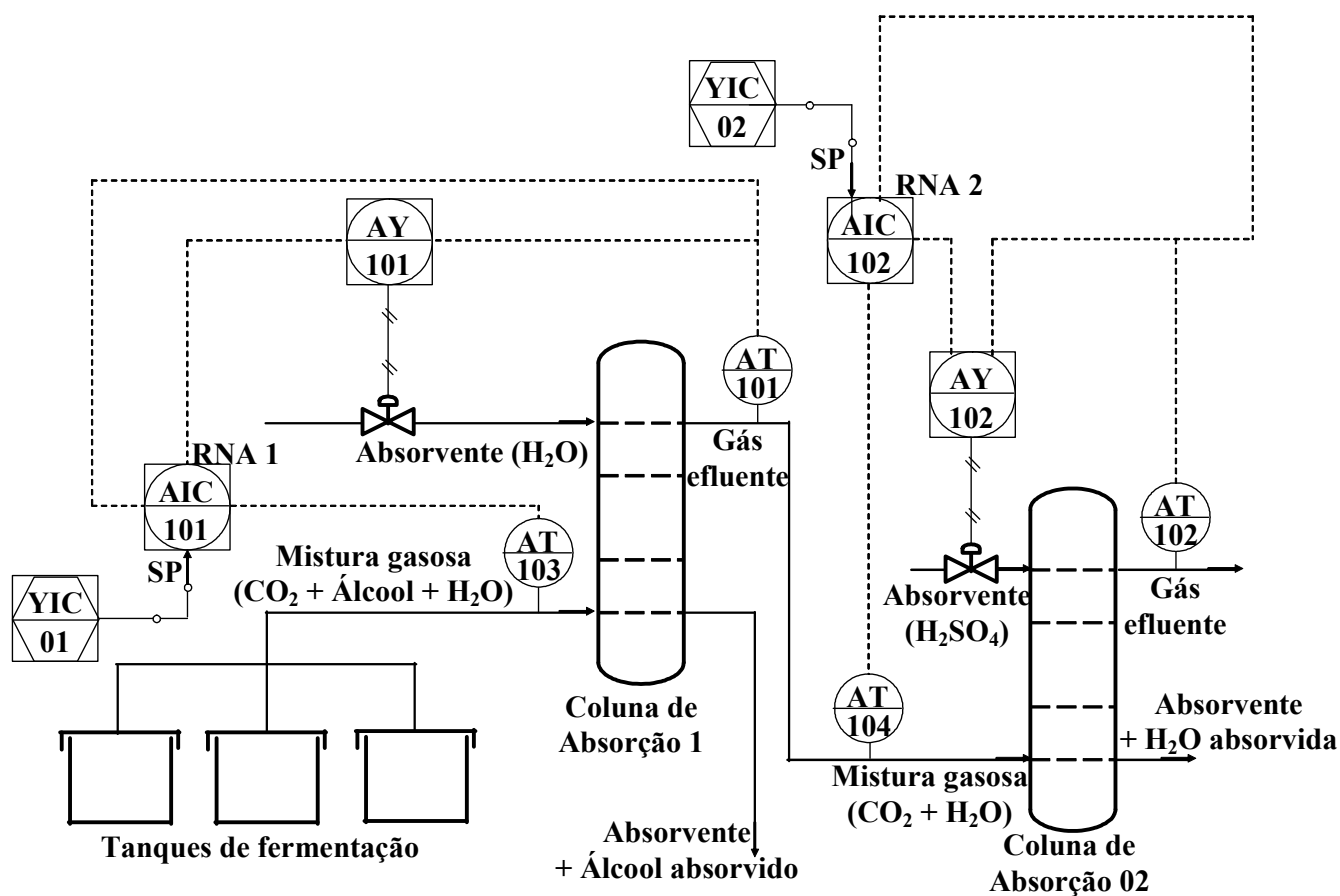


Figura 3.2 – Esquema geral do sistema estudado

Na Tabela 3.1 são apresentados os parâmetros das colunas de absorção estudadas.

Tabela 3.1 – Parâmetros das colunas de absorção estudadas

Parâmetro	Coluna Etanol	Coluna CO ₂
T = Temperatura (°C)	40	30
P = Pressão (atm)	1	1
A _p = Área do prato (cm ²)	210	210
h _v = Altura do vertedouro (cm)	8	8
L _w = Comprimento do vertedouro (cm)	8,3	8,3
N = Número de estágios	9	7
G = Vazão de gás (mol/s)	61,9	60,3
L ₀ = Vazão inicial do líquido absorvente (mol/s)	98,25	1,36

3.3 CONTROLE VIA REDES NEURAIIS

3.3.1 CONSTRUÇÃO DA REDE NEURAL

O sistema de controle empregado nas colunas de absorção de pratos estudadas, consiste na utilização de um controlador *feedforward-feedback* baseado em modelo inverso de redes neurais. O modelo inverso difere do direto na variável predita pela rede, sendo para o primeiro caso, a variável manipulada, e para o segundo, a variável controlada. Nas Figuras 3.3 e 3.4 são apresentados dois esquemas ilustrando o modelo direto e indireto para o problema regulatório e servo, respectivamente. São explicitadas as variáveis de entrada e saída para o sistema estudado, sendo utilizada como base a coluna de absorção responsável pela recuperação do álcool. Deste modo, $L_{0|k}$ é a vazão de solvente no instante atual, $Y1|_k$ representa a fração molar do álcool no gás de saída da coluna no instante atual, e $Y1|_{k-1}$ no instante anterior. Além disso, fazem parte do conjunto de variáveis utilizadas pelo sistema

de controle, a fração molar do álcool desejada (set point) no gás de saída da coluna no instante posterior ($Y_{1sp|k+1}$), a vazão de solvente no instante posterior ($L_{0|k+1}$), e a fração molar do álcool no gás de entrada da coluna no instante atual ($Y_{N+1|k}$), sendo esta última excluída para o problema servo.

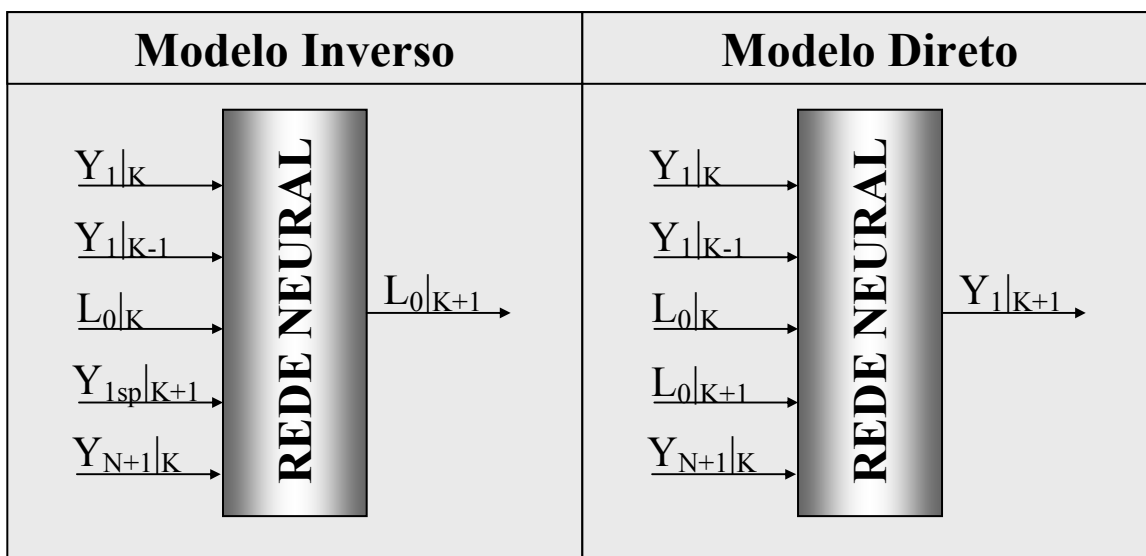


Figura 3.3 – Esquema dos modelos de rede neural (problema regulatório)

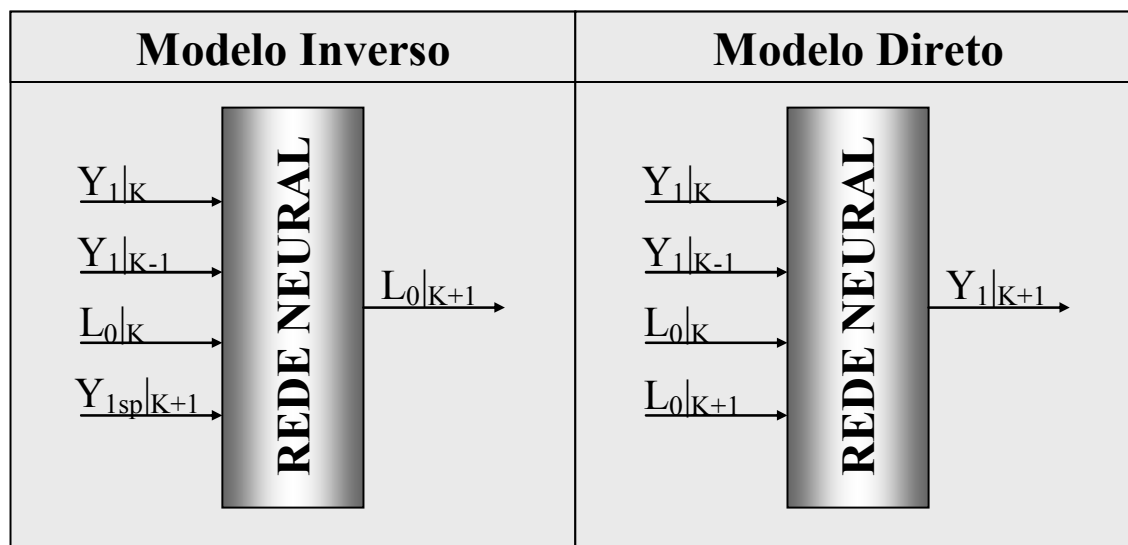


Figura 3.4 – Esquema dos modelos de rede neural (problema servo)

A opção pelo uso do modelo direto implica na necessidade de um processo de otimização para a obtenção da ação de controle. Neste sentido, a rede neural é responsável pela previsão da variável controlada para um dado valor da variável manipulada. Ao receber o valor predito da variável controlada, o otimizador avalia o erro propiciado por esta ação de controle, e caso este erro exceda um nível de tolerância pré-determinado, a ação é descartada e uma nova é calculada. Este procedimento é repetido até que o erro gerado pela ação de controle seja tão pequeno quanto o desejável. Na Figura 3.5 é apresentado um diagrama representativo do controle através do modelo direto de redes neurais.

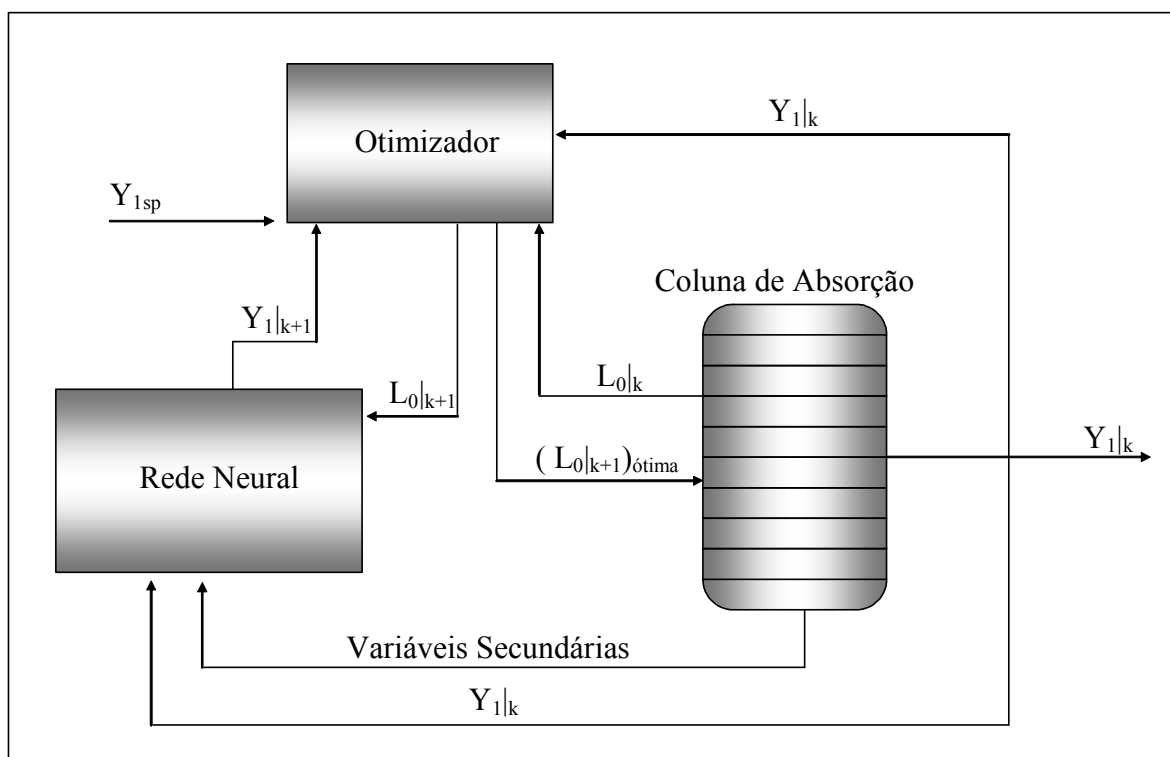


Figura 3.5 – Diagrama do controle da coluna de absorção de pratos através do modelo direto de redes neurais (Controle Preditivo com Modelo)

O modelo inverso, portanto, ao contrário do direto, não necessita de um processo de otimização para definir a ação de controle, o que lhe confere a vantagem de exigir menor esforço computacional. Deste modo, a ação de controle é determinada pela própria rede

neural, conferindo assim, uma maior agilidade ao sistema de controle, fator importante na implementação *on line* do controlador.

Na Figura 3.6 é demonstrado um fluxograma que ilustra a estratégia de controle através do modelo inverso de redes neurais. Este controlador é considerado *feedforward-feedback*, pois a ação de controle é determinada com base tanto em informações referentes a variável distúrbio (ação *feedforward*), quanto no erro implícito na avaliação da variável controlada (ação *feedback*).

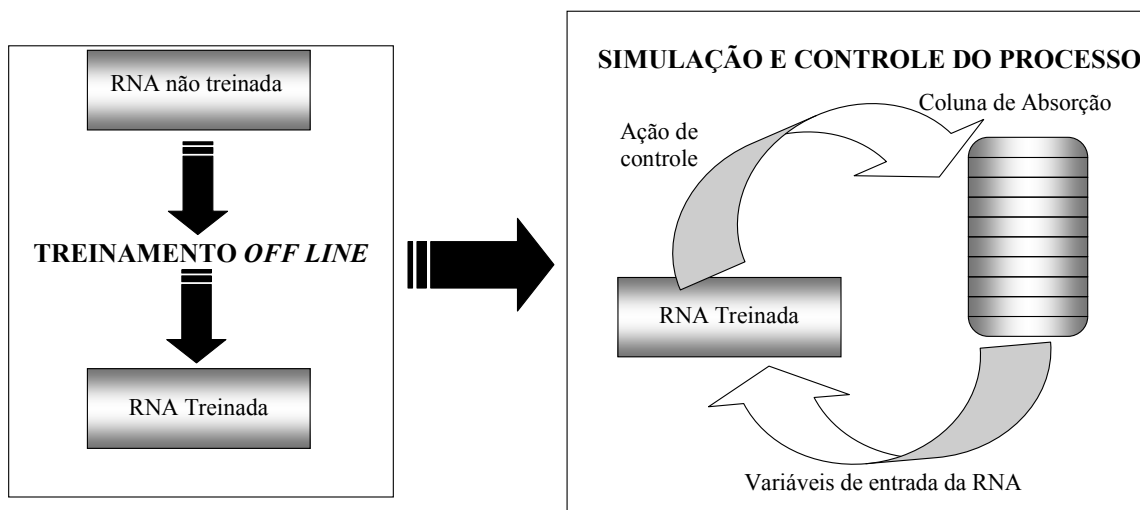


Figura 3.6 – Fluxograma representativo do controle da coluna de absorção de pratos através do modelo inverso de redes neurais (controle *feedforward-feedback*)

A determinação da arquitetura da rede depende de vários fatores, entre eles o número de variáveis de entrada e saída. Conforme demonstrado nas Figuras 3.3 e 3.4, para o modelo inverso de redes neurais, são utilizadas cinco variáveis de entrada para o problema regulatório e quatro para o problema servo, além de uma variável de saída para ambos os casos.

Desta forma, a arquitetura da rede pode ser representada por $5 - m.M - 1$, para o problema regulatório e $4 - m'.M' - 1$ para o problema servo, onde “m”, “m’”, “M” e “M’” correspondem ao número de camadas escondidas e ao número de neurônios em cada camada, respectivamente. Sendo que a determinação destes valores é efetuada de modo a propiciar uma rede que forneça bons resultados sem que haja um esforço computacional excessivo.

3.3.2 TREINAMENTO DA REDE NEURAL

Para que a rede neural forneça resultados satisfatórios, além de uma arquitetura adequada, o processo de treinamento deve ser efetuado com qualidade. Para tanto se faz necessário fornecer à rede, dados representativos da dinâmica do processo.

Neste trabalho, os dados destinados ao treinamento e validação da rede neural foram obtidos utilizando-se o programa computacional desenvolvido para a simulação das colunas de absorção. Deste modo, uma perturbação degrau era inserida ou na composição do gás à entrada da coluna (para o problema regulatório) ou no *set point* (para o problema servo) e a ação do controlador PID (Proporcional Integral Derivativo) fazia com que a variável controlada (composição do gás à saída da coluna) retornasse ao valor desejado. Assim, o valor da variável manipulada a ser implementado na coluna de absorção era determinado pelo controlador PID. As informações referentes a dinâmica da coluna, foram então, agrupadas nos bancos de dados de treinamento e validação das redes. Este procedimento foi repetido várias vezes de modo a realizar a cobertura da faixa de variação da composição do gás à entrada da coluna, que se propunha trabalhar para o problema regulatório (de -10% até +10% para a coluna de recuperação de etanol, e de -5% a +5% para a coluna de tratamento do CO₂), e do *set point* para o problema servo (de -20% a +20% para ambas as colunas), sem que houvesse a tomada de um número excessivo de dados (ocasionando assim, um esforço computacional desnecessário), ou ainda, a qualidade do treinamento fosse comprometida pela ausência de dados.

É necessário efetuar um esclarecimento quanto à necessidade do controlador PID na obtenção dos bancos de dados para o treinamento e validação das redes neurais. Os dados destinados a este fim devem contemplar as informações referentes a relação entre a variável manipulada e controlada. Esta relação é dada pela dinâmica do processo (ou pelas equações de modelagem fenomenológica), ou seja, o modo pelo qual o valor da variável manipulada é obtido, não apresenta relevância sobre a resposta fornecida pelo processo. Assim, este valor pode ser determinado tanto em malha aberta, quanto em malha fechada, de forma manual ou com o auxílio de um controlador qualquer, como o PID.

O método de treinamento utilizado é o da retropropagação através de otimização de Levenberg-Marquardt com regularização Bayesiana. O algoritmo da retropropagação, também conhecido como regra delta generalizada foi proposto por Rumelhart, McClelland e Williams em 1986. Nele, o aprendizado é efetuado com base no erro incluso na resposta fornecida pela rede, o que significa que a diferença entre a resposta atual da simulação e a desejada deve ser minimizada, sendo necessário, portanto, o ajuste dos pesos sinápticos associados às entradas dos neurônios. Assim, o erro calculado na camada de saída é retropropagado às demais camadas, servindo de base para a modificação de todos os pesos, até que a resposta obtida pela rede seja satisfatória.

Como apresentado no Capítulo 2, uma das vantagens do algoritmo de Levenberg-Marquardt com Regularização Bayesiana é o fornecimento do valor de γ (parâmetros da rede que estão efetivamente sendo utilizados). De acordo com o critério de FORESSE e HAGAN (1997), esta medida pode ser empregada no dimensionamento da rede. Caso o valor de γ seja muito próximo do número total de parâmetros (N), então se deve aumentar o tamanho da rede (aumentando o número de neurônios na camada intermediária), pois a rede pode não ser grande o suficiente para tratar o problema em questão. Este procedimento deve ser repetido até que γ se torne constante, não importando quão grande seja N.

Além do critério de FORESSE e HAGAN (1997), também foram utilizados a soma dos quadrados dos erros (SSE) e a média dos quadrados dos erros (MSE) para determinar a melhor estrutura de rede. Os valores de SSE e MSE foram obtidos através das Equações 3.01 e 3.02.

$$SSE = \sum_{i=1}^P (Y_{saída} - Y)_i^2 \quad (3.01)$$

Onde:

$Y_{saída}$ = Resposta da RNA.

Y = Dado de treinamento/validação.

P = Número de conjuntos entrada-saída.

$$MSE = \frac{SSE}{[N^0 \text{ de conjuntos entrada - saída}] * [N^0 \text{ de neurônios na camada de saída}]} \quad (3.02)$$

3.4 SINTONIA DOS PARÂMETROS DO CONTROLADOR PID

Neste trabalho o controlador PID foi utilizado como base para a comparação de desempenho com o controlador RNA proposto. Deste modo, para assegurar o melhor desempenho possível do PID procedeu-se a sintonia de seus parâmetros, partindo-se de uma estimativa inicial e prosseguindo-se a busca através do método de tentativa e erro até que fosse encontrado o melhor conjunto de valores para aqueles. Para a coluna de recuperação de etanol a estimativa inicial dos parâmetros do PID foi feita de maneira arbitrária. Já para a coluna de tratamento de CO₂ esta estimativa foi feita utilizando-se equações baseadas no critério de desempenho ITAE (SMITH, 2008).

Para o problema regulatório:

$$k_C = \frac{a_1}{k_P} \left(\frac{t_d}{\tau_P} \right)^{b_1} \quad (3.03)$$

$$\tau_I = \frac{\tau_P}{a_2} \left(\frac{t_d}{\tau_P} \right)^{b_2} \quad (3.04)$$

$$\tau_D = a_3 \tau_P \left(\frac{t_d}{\tau_P} \right)^{b_3} \quad (3.05)$$

Para o problema servo são utilizadas as mesmas expressões para k_C e τ_D . Já τ_I é calculado pela Equação 3.06.

$$\tau_I = \frac{\tau_P}{a_2 + b_2 \left(\frac{t_d}{\tau_P} \right)} \quad (3.06)$$

Os valores para os coeficientes a_1 , a_2 , a_3 , b_1 , b_2 e b_3 são apresentados na Tabela 3.2 (SMITH, 2008).

Tabela 3.2 – Coeficientes para a estimativa dos parâmetros do PID (SMITH, 2008)

Problema regulatório					
a₁	a₂	a₃	b₁	b₂	b₃
1,357	0,842	0,381	-0,947	0,738	0,995
Problema servo					
a₁	a₂	a₃	b₁	b₂	b₃
0,965	0,796	0,308	-0,855	-0,147	0,9292

3.5 IMPLEMENTAÇÃO DAS INCERTEZAS NOS SENSORES

Devido às incertezas de medição incluídas na tomada de dados, principalmente na determinação da concentração de etanol/água na corrente gasosa tanto à entrada quanto à saída das colunas de absorção, os valores disponibilizados como variáveis de entrada para a rede neural diferem dos reais. Esta diferença pode causar uma queda de desempenho do sistema de controle.

Visando enriquecer a simulação quanto a influência das incertezas de medição no desempenho do controle RNA, estas foram inseridas nas medidas de concentração de etanol/água residual nas correntes gasosas, segundo a Equação 3.07.

$$Y_u = Y \left(1 + \frac{R.U}{100} \right) \quad (3.07)$$

Onde:

Y_u = Variável com incerteza de medição.

Y = Variável sem incerteza de medição.

R = Número aleatório entre -1 e +1.

U = Nível de incerteza (%).

Foram testados três níveis de incerteza para as colunas estudadas: 5%, 10% e 15%. Neste sentido, para cada instante de amostragem a magnitude da incerteza inserida mudava respeitando o nível máximo analisado.

3.6 CRITÉRIOS DE AVALIAÇÃO DE DESEMPENHO

Além da análise do comportamento da variável controlada frente a perturbações degrau inseridas ou na concentração de etanol/água na corrente gasosa à entrada da coluna (problema regulatório) ou no *set point* (problema servo), observando-se o *overshoot* e o tempo de resposta proporcionado pela ação dos controladores RNA e PID, optou-se por utilizar outros parâmetros de avaliação de desempenho, sendo eles a integral do erro absoluto ponderada pelo tempo (ITAE), integral do erro absoluto (IAE) e integral do quadrado do erro (ISE). Os valores destes parâmetros foram calculados fazendo uso das Equações 3.08, 3.09 e 3.10.

$$ITAE = \int |e| \cdot t \, dt \quad (3.08)$$

$$IAE = \int |e| \, dt \tag{3.09}$$

$$ISE = \int (e)^2 \, dt \tag{3.10}$$

CAPÍTULO 4

RESULTADOS

4.1 INTRODUÇÃO

Neste capítulo são apresentados, inicialmente, alguns resultados disponíveis na literatura que são relevantes ao presente trabalho. Na sequência são apresentados os resultados preliminares onde é avaliada a não linearidade do sistema estudado. Também são expostos os resultados referentes ao desempenho da estratégia de controle proposta, no tratamento do problema regulatório e servo, efetuando-se um comparativo com o desempenho propiciado por um controlador PID. Além disso, os resultados obtidos das simulações nas quais as incertezas nos sensores foram inseridas também são apresentados.

4.2 RESUMO DOS RESULTADOS DISPONÍVEIS NA LITERATURA

A seguir são apresentados alguns dos resultados disponíveis na literatura com relação ao controle da coluna de absorção para recuperação de etanol estudada.

Em seu trabalho, PALÚ (2001) aplicou a estratégia de controle DMC à coluna de recuperação de etanol. Dentre outros tópicos desenvolvidos, efetuou-se a sintonia dos parâmetros do controlador DMC objetivando a melhora do desempenho do mesmo. Depois de definidos os melhores valores para estes ($f=0$, $V=4$, $U=2$ e $T=10$), os quais agregam um desempenho satisfatório a um esforço computacional razoável, foi efetuada uma comparação entre aquele controlador e um controlador clássico, PI (Proporcional Integral). A Figura 4.1 demonstra a superioridade do DMC em relação ao PI, pois além da resposta apresentar um menor *overshoot*, o estado estacionário é obtido mais rapidamente. Já na Figura 4.2 é exposto o comportamento da variável manipulada sob a ação do DMC.




Figura 4.1 – Comparação entre o desempenho dos controladores DMC e PI (problema SISO, perturbação única) (PALÚ, 2001).




Figura 4.2 – Comportamento da variável manipulada sob a ação do controlador DMC (problema SISO, perturbação única) (PALÚ, 2001).

O controle da coluna de recuperação de etanol também foi abordado em EYNG (2006), sendo aplicado uma estratégia de controle baseada em modelo inverso de redes neurais artificiais. Neste trabalho foi apresentado um comparativo de desempenho entre o controlador neural e o DMC aplicado por PALÚ (2001). A Figura 4.3 constitui um dos resultados demonstrativos da superioridade do controlador neural. Na seqüência a Figura 4.4 demonstra o comportamento da variável manipulada para o sistema sob o controle neural e DMC.




Figura 4.3 – Comparação entre o desempenho dos controladores RNA e DMC (EYNG, 2006)




Figura 4.4 – Vazão de solvente determinada pelos controladores RNA e DMC (EYNG, 2006)

Em EYNG (2006) também foi testado a inserção de ruído nos valores das variáveis de entrada da rede do tipo concentração de etanol na corrente gasosa, com posterior filtragem destes valores distorcidos pelo ruído. A Figura 4.5 apresenta o comportamento da variável controlada para o sistema sob o controle RNA alimentado com as variáveis distorcidas pela inserção do ruído. Apesar de não conseguir estabilizar a variável no *set point* a amplitude da faixa de oscilação foi reduzida a metade do ruído empregado. Já na Figura 4.6 é apresentado o resultado de uma simulação na qual os dados de entrada do controlador RNA foram distorcidos pelo ruído e posteriormente filtrados. Com a utilização do filtro de média móvel, a amplitude da faixa de oscilação foi reduzida a aproximadamente 75% do ruído empregado.




Figura 4.5 – Desempenho do controlador RNA para uma situação na qual os dados de entrada da rede apresentam ruído (EYNG, 2006)




Figura 4.6 – Resposta do processo para uma situação na qual as variáveis de entrada da rede são distorcidas pelo ruído e atenuadas pelo filtro (EYNG, 2006)

4.3 RESULTADOS PRELIMINARES: AVALIAÇÃO DA NÃO LINEARIDADE DO SISTEMA

De posse dos modelos dinâmicos das colunas de absorção de pratos estudadas, foi possível avaliar o comportamento do processo em malha aberta. O intuito dos testes realizados foi o de avaliar a não linearidade do sistema.

Os dois primeiros testes referem-se a coluna de absorção destinada a recuperação do etanol. Foram analisadas as relações entre a variável controlada (concentração do álcool no gás à saída da coluna, Y_1) e a variável distúrbio (concentração do álcool no gás à entrada da coluna, Y_{N+1}) e a variável manipulada (vazão de solvente alimentada à coluna, L_0).

O procedimento adotado nestes testes consistiu na inserção de perturbações degrau de diferentes magnitudes em Y_{N+1} e em L_0 , respectivamente, observando-se o comportamento de Y_1 na seqüência.

A análise dos resultados obtidos, objetivando a avaliação da não linearidade do sistema, foi realizada com base no cálculo da relação entre a variação observada em Y_1 e a variação implementada em Y_{N+1} ou L_0 (Eq. 4.01).

$$\frac{\Delta Y_1 (\%)}{\Delta Y_{N+1} (\%) \text{ ou } \Delta L_0 (\%)} \quad (4.01)$$

Na Figura 4.7 é apresentado um gráfico demonstrativo dos resultados obtidos para a análise da relação entre Y_1 e Y_{N+1} . Nota-se que a proporcionalidade entre a variação destas duas variáveis é um indicativo da linearidade desta relação.




Figura 4.7 – Gráfico ΔY_1 x ΔY_{N+1} para avaliação da não linearidade

Na Figura 4.8 é apresentado um gráfico referente aos resultados obtidos para a relação entre as variáveis Y_1 e L_0 . Nota-se que a proporcionalidade verificada na Figura 4.7 não se repete para estas variáveis, demonstrando o caráter não linear desta relação. Neste sentido, um controlador neural, devido à capacidade de processamento das redes neurais artificiais, deve proporcionar um melhor desempenho em relação a um controlador linear como o PID.




Figura 4.8 – Gráfico ΔY_1 e ΔL_0 para avaliação da não linearidade

O mesmo procedimento adotado para a avaliação da não linearidade da coluna de absorção destinada à recuperação do etanol também foi aplicado à coluna de absorção empregada no tratamento do gás carbônico. Assim, foi possível analisar a relação entre a variável controlada Y_1' (concentração de água no gás à saída da coluna) e as variáveis, distúrbio Y_{N+1}' (concentração de água no gás à entrada da coluna) e manipulada L_0' (vazão de solvente alimentada a coluna), respectivamente.

Na Figura 4.9 é apresentado um gráfico demonstrativo dos resultados obtidos para a avaliação da não linearidade da relação entre as variáveis Y_1' e Y_{N+1}' . Nota-se que a proporcionalidade entre as duas variáveis indica a fraca não linearidade desta relação.




Figura 4.9 – Gráfico $\Delta Y_1'$ x $\Delta Y_{N+1}'$ para avaliação da não linearidade

Na Figura 4.10 é apresentado um gráfico referente aos resultados obtidos para a avaliação da não linearidade entre as variáveis $\Delta Y_1'$ e $\Delta L_0'$. Nesta relação também é possível perceber uma fraca não linearidade, devido à proporcionalidade verificada entre as variações destas variáveis. Com base no grau de linearidade demonstrado pela coluna de absorção para tratamento do gás carbônico, espera-se que o desempenho de um controlador neural e o do PID se assemelhem.




Figura 4.10 – Gráfico $\Delta Y_1'$ e $\Delta L_0'$ para avaliação da não linearidade

4.4 CONSTRUÇÃO DO CONJUNTO DE DADOS DE TREINAMENTO E VALIDAÇÃO PARA AS REDES NEURAIS ARTIFICIAIS

Antes de dar início a construção do conjunto de dados destinado ao treinamento e validação das redes neurais artificiais, foi determinado o tempo de amostragem para as duas colunas.

Para tanto, partiu-se de um critério prático no qual o tempo de amostragem (TA) assume valor entre 10 e 20% da constante de tempo do processo. Para a coluna de absorção destinada a recuperação do etanol, foi verificado que o sistema se comporta como sendo de primeira ordem, de acordo com a Figura 4.11. Já para a coluna de tratamento de CO₂ apesar do sistema ser de segunda ordem, foi feito uma aproximação para um sistema de primeira ordem com tempo morto, conforme Figura 4.12. Para a primeira coluna o valor da constante de tempo é obtido no ponto onde a resposta do processo assume 63,3% do valor final da resposta.

Visando a determinação da constante de tempo das colunas, e posterior cálculo do tempo de amostragem, inseriu-se uma perturbação degrau de -10% na variável manipulada,

sendo observado o comportamento da variável controlada. No caso da coluna de absorção para recuperação do etanol, conforme Figura 4.11, pode-se notar que quando Y_1 assume valor igual a 263 ppm (63,3% da resposta final do processo), obtém-se $\tau_p \approx 20s$.




Figura 4.11 – Determinação do instante de amostragem (TA) para a coluna de absorção para recuperação do etanol

Na Figura 4.12 são apresentadas tanto a resposta do processo quanto a curva resultante da aproximação para um sistema de primeira ordem com tempo morto, para a coluna de absorção responsável pelo tratamento do CO_2 .




Figura 4.12 – Determinação do instante de amostragem (TA) para a coluna de absorção para desidratação do CO₂

Segundo STEPHANOPOULOS (1984) o tempo morto, t_d pode ser determinado diretamente da resposta do processo, conforme Figura 4.12. Já a constante de tempo do processo (τ_p) pode ser determinada através da seguinte equação:

$$\tau_p = B/S \quad (4.02)$$

Onde:

B = Valor final da resposta do processo no estado estacionário.

S = Coeficiente angular da reta tangente ao ponto de inflexão.

Deste modo, para a coluna de tratamento de CO_2 , o tempo morto é de aproximadamente 15,2 s e a constante de tempo (utilizando a Equação 4.01) é 108,8 s.

Sendo assim, para a primeira coluna seria possível utilizar um tempo de amostragem entre 2 e 4 s e para a segunda, entre 10,9 e 21,8 s, aproximadamente. Para padronizar o tempo de amostragem das duas colunas, optou-se por utilizar 3 s, uma vez que este valor se encontra dentro da faixa de menor magnitude com relação ao TA. No caso da segunda coluna, este valor estaria além do requerido, no entanto, este fato não deve causar qualquer transtorno, pois, somente existiriam problemas para capturar a dinâmica da coluna, se o tempo de amostragem fosse superior a 21,8 s.

Para a construção do banco de dados de treinamento da rede neural artificial destinada à coluna de absorção para recuperação de etanol foram utilizados dados gerados pelo programa computacional em linguagem Fortran, desenvolvido por PALÚ (2001). Este programa traz o algoritmo do *Dynamic Matrix Control* (DMC) implementado àquela coluna.

O procedimento adotado para a construção do banco de dados de treinamento foi o da inserção de perturbações degrau de diferentes magnitudes na composição do gás à entrada da coluna, e posterior verificação da resposta do processo sob controle DMC.

A faixa de distúrbio que se propôs trabalhar foi de -10% à +10% para Y_{N+1} . Assim, realizou-se a cobertura desta faixa, implementando-se perturbações degrau com incremento de 1%.

Para a construção do banco de dados destinado à validação do treinamento da rede, também se obedeceu a faixa de trabalho utilizada, entretanto, os valores das perturbações foram escolhidos aleatoriamente, incluindo tanto valores presentes no banco de dados de treinamento quanto inéditos, testando a capacidade de generalização da rede.

Os dados destinados à construção do banco de dados de treinamento e validação da rede neural artificial para o controle da coluna de absorção responsável pelo tratamento do CO_2 foram gerados pelo programa computacional desenvolvido para a simulação deste equipamento, fazendo uso do controlador PID (Proporcional Integral Derivativo) para realizar a manipulação da vazão de solvente, foi adotado o mesmo procedimento aplicado à outra coluna, no entanto, a faixa de distúrbio que se propôs trabalhar foi de -5% a 5% para Y_{N+1} , com incremento de 0,5%.

É interessante ressaltar que os dados destinados ao treinamento da rede devem conter informações sobre a relação entre a variável manipulada (neste caso, a vazão de solvente) e a variável controlada. Esta relação é dada pela dinâmica do processo (ou pelas equações de modelagem fenomenológica), ou seja, o modo pelo qual o valor da variável manipulada é alterado, não apresenta relevância sobre a resposta fornecida pelo processo. Deste modo, este valor pode ser determinado tanto em malha aberta, quanto em malha fechada, de forma manual ou com o auxílio de um controlador qualquer, como o PID ou ainda, o DMC.

As variáveis de entrada e saída, que foram inicialmente utilizadas para a constituição dos bancos de dados de treinamento e validação das redes neurais artificiais estão demonstradas na Tabela 4.1.

Tabela 4.1 – Variáveis de entrada e saída das redes neurais artificiais

COLUNA DE ABSORÇÃO PARA RECUPERAÇÃO DO ETANOL	
VARIÁVEIS DE ENTRADA	VARIÁVEIS DE SAÍDA
<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo atual ($L_0 _k$) • Concentração de álcool no gás à saída da coluna no instante de tempo atual ($Y_1 _k$) • Concentração de álcool no gás à saída da coluna no instante de tempo anterior ($Y_1 _{k-1}$) • Concentração desejada de álcool no gás à saída da coluna no instante de tempo posterior ($Y_{1sp} _{k+1}$) • Concentração de álcool no gás à entrada da coluna no instante de tempo atual ($Y_{N+1} _k$) 	<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo posterior ($L_0 _{k+1}$)

Continuação Tabela 4.1

COLUNA DE ABSORÇÃO PARA TRATAMENTO DO CO₂	
VARIÁVEIS DE ENTRADA	VARIÁVEIS DE SAÍDA
<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo atual ($L_0 _k'$) • Concentração de água no gás à saída da coluna no instante de tempo atual ($Y_1 _k'$) <p>Concentração de água no gás à saída da coluna no instante de tempo anterior ($Y_1 _{k-1}'$)</p> <ul style="list-style-type: none"> • Concentração desejada de água no gás à saída da coluna no instante de tempo posterior ($Y_{1sp} _{k+1}'$) • Concentração de água no gás à entrada da coluna no instante de tempo atual ($Y_{N+1} _k'$) 	<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo posterior ($L_0 _{k+1}'$)

4.5 CONSTRUÇÃO DO PROGRAMA COMPUTACIONAL PARA CRIAÇÃO E TREINAMENTO DA REDE NEURAL ARTIFICIAL

Para cada coluna de absorção que se deseja implementar o controlador *feedforward-feedback* baseado no modelo inverso de redes neurais deve-se criar e treinar uma RNA. Com esta finalidade, foram desenvolvidos dois programas computacionais, fazendo uso do *software* Matlab[®], conforme anexos 2 e 5.

O método de treinamento utilizado foi o da retropropagação através de otimização de Levenberg-Marquardt com regularização Bayesiana, sendo que seu algoritmo está disponível para uso no *software* Matlab[®], através da função *trainbr*.

4.6 IMPLEMENTAÇÃO DO CONTROLADOR NEURAL BASEADO NO MODELO INVERSO DE REDES NEURAIIS

4.6.1 DETERMINAÇÃO DA ARQUITETURA DA REDE

Foram testadas várias arquiteturas para as redes neurais, no entanto, a primeira camada (entrada) e a última (saída) foram mantidas inalteradas. Sendo assim, na primeira camada foram dispostos cinco neurônios, cada qual trabalhando como um sensor na identificação do valor referente a uma variável de entrada, e analogamente, um nodo constituiu a camada de saída, sendo responsável pelo fornecimento da resposta da rede. Esta resposta, de acordo com o modelo inverso de redes neurais utilizado, corresponde ao novo valor da variável manipulada a ser implementado, ou seja, representa a própria ação de controle.

Quanto ao número de camadas intermediárias, bem como a quantidade de nodos em cada uma delas, buscou-se um arranjo capaz de proporcionar um treinamento de qualidade, com capacidade de generalização e reprodutibilidade, sem que houvesse um acréscimo exagerado no esforço computacional.

A Tabela 4.2 apresenta os valores da soma dos erros quadrados (SSE) e da média dos erros quadrados (MSE) para os conjuntos de treinamento e validação, obtidos para diferentes estruturas de rede para a coluna de recuperação de etanol. Nota-se que estruturas superiores a 5 – 5 – 1 são equivalentes quanto aos parâmetros SSE e MSE, na fase de treinamento, assim como no teste feito com o conjunto de dados de validação. Sendo assim, uma arquitetura com duas camadas intermediárias pode ser descartada, pois esta resultaria em um acréscimo de esforço computacional, sem propiciar um aumento de desempenho significativo.

Tabela 4.2 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação do etanol)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE*	SSE (mol²/s²)	MSE*
5 – 4 – 1	12,080E-7	1,4748E-9	2,0437	4,1879E-3
5 – 5 – 1	23,570E-7	2,8785E-9	2,0489	4,1985E-3
5 – 6 – 1	9,8429E-7	1,2018E-9	2,0515	4,2038E-3
5 – 7 – 1	9,9674E-7	1,2170E-9	2,0650	4,2315E-3
5 – 8 – 1	9,9988E-7	1,2208E-9	2,1112	4,3262E-3
5 – 9 – 1	9,9907E-7	1,2199E-9	2,0425	4,1854E-3
5 – 10 – 1	9,9913E-7	1,2199E-9	2,0850	4,2725E-3
5 – 11 – 1	9,9493E-7	1,2148E-9	2,1511	4,4079E-3
5 – 12 – 1	9,9971E-7	1,2206E-9	2,0380	4,1762E-3
5 – 13 – 1	9,9984E-7	1,2208E-9	2,0632	4,2278E-3
5 – 14 – 1	9,9973E-7	1,2207E-9	2,0862	4,2750E-3
5 – 15 – 1	9,9985E-7	1,2192E-9	2,1559	4,4178E-3
5 – 5 – 5 – 1	9,9898E-7	1,2197E-9	2,0544	4,2098E-3
5 – 6 – 6 – 1	9,9942E-7	1,2203E-9	2,1215	4,3473E-3
5 – 7 – 7 – 1	0,2022E-7	2,4686E-9	2,0963	4,2956E-3

* mol²/([s²] . [n° de dados entradas-saída] . [n° de neurônios na camada de saída])

Além dos parâmetros demonstrados na Tabela 4.2, analisou-se o comportamento do número de parâmetros efetivamente utilizados pela rede (γ) e do número de parâmetros totais (N'), em relação ao número de neurônios na camada intermediária. De acordo com o critério de FORESSE E HAGAN (1997) caso o valor de γ seja muito próximo do número total de parâmetros (N'), então se deve aumentar o tamanho da rede (aumentando o número de neurônios na camada intermediária), pois a rede pode não ser grande o suficiente para tratar o problema em questão. Este procedimento deve ser repetido até que γ se torne constante, não importando quão grande seja N' . O resultado deste teste é apresentado na Figura 4.13.




Figura 4.13 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol)

Observando-se a Figura 4.13 pode-se perceber que a partir de 9 neurônios na camada intermediária, o número de parâmetros que são realmente utilizados pela RNA permanece praticamente constante. Sendo assim, seguindo o critério de FORESSE e HAGAN (1997) optou-se por utilizar este número de nodos na camada intermediária.

Portanto, os melhores resultados foram obtidos quando utilizada apenas uma camada intermediária, composta por nove unidades de processamento, sendo a arquitetura

5 – 9 – 1, a que melhor se adequou ao sistema estudado. A Figura 4.14 demonstra a relação obtida entre a resposta fornecida pela rede, de estrutura igual à mencionada, e a resposta desejada, sendo que para este teste, fez-se uso do banco de dados de validação. Nota-se que o desempenho da rede foi satisfatório, proporcionando um índice de correlação de 0,997. Além disso, o ajuste efetuado para o conjunto de dados testados proporcionou um coeficiente angular de 0,985 (cujo valor ótimo seria 1) e um coeficiente linear de 1,51 (cujo valor ótimo seria 0). Desta forma, percebe-se que a rede adquiriu a capacidade de generalizar os dados apresentados a ela na etapa de treinamento, sendo evitado, portanto, o sobre-ajuste. Deve-se ressaltar ainda, que evitar tal problema é uma característica do método de treinamento utilizado.




Figura 4.14 – Relação entre a resposta fornecida pela rede e a saída desejada para o conjunto de validação (Coluna de absorção para recuperação de etanol)

A Tabela 4.3 apresenta os valores da soma dos erros quadrados (SSE) e da média dos erros quadrados (MSE) para os conjuntos de treinamento e validação, obtidos para

diferentes estruturas de rede para a coluna de desidratação do CO₂. Nota-se que estruturas superiores a 5 – 15 – 1 são equivalentes quanto aos parâmetros SSE e MSE, tanto na fase de treinamento, quanto no teste feito com o conjunto de dados de validação. Desta forma, assim como para a outra coluna de absorção, uma arquitetura de rede com duas camadas intermediárias pode ser descartada.

Tabela 4.3 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para desidratação do CO₂)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE*	SSE (mol²/s²)	MSE*
5 – 10 – 1	5,5854E-6	5,4492E-9	3,9476E-9	1,9351E-11
5 – 11 – 1	7,3523E-6	7,1730E-9	4,3324E-9	2,1237E-11
5 – 12 – 1	6,2577E-6	6,1051E-9	3,3883E-9	1,6609E-11
5 – 13 – 1	6,3091E-6	6,1552E-9	2,7913E-9	1,3683E-11
5 – 14 – 1	5,3934E-6	5,2619E-9	2,7465E-9	1,3463E-11
5 – 15 – 1	9,9997E-6	9,7558E-10	5,5424E-10	2,7169E-12
5 – 16 – 1	9,9979E-6	9,7540E-10	5,5359E-10	2,7137E-12
5 – 17 – 1	9,9991E-6	9,7552E-10	4,3306E-10	2,1228E-12
5 – 18 – 1	9,9913E-6	9,7476E-10	4,7558E-10	2,3313E-12
5 – 19 – 1	9,9842E-6	9,7407E-10	4,2022E-10	2,0599E-12
5 – 20 – 1	9,9630E-6	9,7200E-10	6,0905E-10	2,9855E-12
5 – 21 – 1	9,9964E-6	9,7526E-10	4,0055E-10	1,9635E-12

Continuação Tabela 4.3

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE[*]	SSE (mol²/s²)	MSE[*]
5 – 22 – 1	9,9932E-7	9,7495E-10	4,8382E-10	2,3717E-12
5 – 25 – 1	9,9945E-7	9,7507E-10	3,5276E-10	1,7292E-12
5 – 30 – 1	9,9912E-7	9,7475E-10	3,8215E-10	1,8733E-12
5 – 35 – 1	9,9989E-7	9,7550E-10	4,1379E-10	2,0284E-12
5 – 40 – 1	9,9876E-7	9,7440E-10	4,6541E-10	2,2814E-12
5 – 5 – 5 – 1	7,0714E-6	6,8989E-9	4,8201E-10	2,3628E-12
5 – 6 – 6 – 1	9,9988E-7	9,7549E-10	6,5903E-10	3,2305E-12
5 – 7 – 7 – 1	9,9977E-7	9,7539E-10	7,2761E-10	3,5667E-12

^{*} mol²/([s²] . [nº de dados entradas-saída] . [nº de neurônios na camada de saída])

O comportamento do número de parâmetros efetivamente utilizados pela rede (γ) e do número de parâmetros totais (N'), em relação ao número de neurônios na camada intermediária, para a coluna de desidratação do CO₂, é demonstrado na Figura 4.15.




Figura 4.15 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para desidratação do CO₂)

Observando-se a Figura 4.15 pode-se perceber que a partir de 22 neurônios na camada intermediária, o número de parâmetros que são realmente utilizados pela RNA permanece praticamente constante. Novamente fazendo uso do critério de FORESSE e HAGAN (1997), optou-se por utilizar este número de nodos na camada intermediária.

Assim, os melhores resultados foram obtidos quando utilizada apenas uma camada intermediária, composta por vinte e duas unidades de processamento, sendo a arquitetura 5 – 22 – 1, a que melhor se adequou ao sistema estudado. A Figura 4.16 demonstra a relação obtida entre a resposta fornecida pela rede e a resposta desejada, sendo que para este teste, fez-se uso do banco de dados de validação. Nota-se que o desempenho da rede foi muito bom, uma vez que o índice de correlação assumiu valor igual à unidade. Além disso, o ajuste efetuado para o conjunto de dados testados proporcionou um coeficiente angular de 1 (considerado valor ótimo) e um coeficiente linear de $-8,84 \cdot 10^{-6}$ (cujo valor ótimo seria 0).




Figura 4.16 – Relação entre a resposta fornecida pela rede e a saída desejada para o conjunto de validação (Coluna de absorção para desidratação do CO_2)

4.6.2 DESEMPENHO DO CONTROLE RNA

Depois de definidas as arquiteturas das redes neurais artificiais, foi possível implementar o controle via redes neurais nas duas colunas de absorção do processo de produção de etanol.

Na Figura 4.17 é apresentado um gráfico demonstrativo da resposta do processo (coluna de absorção para recuperação do etanol), sob o controle via redes neurais proposto, quando submetido a uma perturbação degrau de 8,7% em Y_{N+1} . Nota-se que o controlador foi capaz de fazer com que a composição do gás à saída da coluna, Y_1 (variável controlada), voltasse ao *set point*, sendo necessário para que isto ocorresse, cerca de 125 segundos. O comportamento da variável manipulada (vazão de solvente L_0), é demonstrado na Figura 4.18.




Figura 4.17 - Resposta do processo em malha fechada com RNA frente a uma perturbação degrau (Coluna para recuperação de etanol)




Figura 4.18 - Comportamento da variável manipulada frente a uma perturbação degrau (Coluna para recuperação de etanol)

Nas Figura 4.19 e 4.20 são apresentados, respectivamente, os comportamentos das variáveis controlada e manipulada da coluna de absorção responsável pela desidratação do CO_2 . Neste teste, uma perturbação degrau de 4,3% foi inserida em Y_{N+1} . É possível perceber que o controlador fez com que a variável controlada retornasse ao *set point*, sendo estabilizada assim como na outra coluna, em cerca de 125 segundos.




Figura 4.19 - Resposta do processo em malha fechada com RNA frente a uma perturbação degrau (Coluna para desidratação do CO_2)




Figura 4.20 - Comportamento da variável manipulada frente a uma perturbação degrau (Coluna para desidratação do CO_2)

4.7 INSERÇÃO DE DISTÚRPIO NÃO PREVISTO NA ETAPA DE TREINAMENTO (X_0) E POSTERIOR ATUALIZAÇÃO DESTE BANCO DE DADOS

O sucesso da estratégia de controle proposta está diretamente vinculado a eficiência da rede neural artificial que constitui sua base. Após a etapa de treinamento, a rede está apta a trabalhar nas condições de operação para as quais foi preparada, no entanto, distúrbios não contemplados no treinamento podem ocorrer, aumentando a probabilidade de queda de eficiência por parte da rede neural artificial.

Para simular tal situação, na Figura 4.21 é apresentado o resultado de um teste no qual foi inserida uma perturbação degrau de 5,6% na concentração de álcool na corrente de solvente que é alimentada à coluna de absorção destinada à recuperação do etanol (X_0). São demonstrados o comportamento da variável controlada, Y_1 , para o sistema monitorado pelo controlador RNA, com a rede neural artificial inicialmente treinada na ausência deste tipo de distúrbio, e posteriormente, com o banco de dados atualizado, incluindo tal perturbação.

Observa-se que com a inclusão da variável X_0 no treinamento da rede neural artificial, o off-set é extinto, demonstrando a evolução da rede.




Figura 4.21 – Comparativo entre desempenho do controlador RNA com X_0 ausente no treinamento, e incluído (Perturbação em X_0)

Na Figura 4.22 é demonstrado o comportamento de Y_1 em uma simulação na qual uma perturbação degrau de 8,7% foi inserida em X_0 simultaneamente à inserção de uma perturbação degrau de 9,3% em Y_{N+1} , sendo que este último distúrbio já fora incluído no treinamento anteriormente. Novamente, o controlador RNA com banco de dados de treinamento atualizado (incluindo a variável X_0) demonstrou ser superior, eliminando o off-set.




Figura 4.22 – Comparativo entre desempenho do controlador RNA com X_0 ausente no treinamento, e incluído (Perturbação em X_0 e Y_{N+1} , simultaneamente)

4.8 AVALIAÇÃO DA AÇÃO *FEEDBACK* DO CONTROLADOR RNA

Para avaliar a influência da ação *feedback* no desempenho do controlador RNA, foi realizado um teste excluindo Y_1 das variáveis de entrada da rede. Neste sentido, inseriu-se uma perturbação degrau de 9,7% em Y_{N+1} e observou-se o comportamento da variável controlada, Y_1 , sob a monitoração do controlador RNA com as duas arquiteturas de rede: 5 – 9 – 1 (sendo as variáveis de entrada: $Y_1|_k$, $Y_1|_{k-1}$, Y_{1SP} , $L_0|_k$, $Y_{N+1}|_k$) e 3 – 9 – 1 (excluindo as variáveis de entrada $Y_1|_k$ e $Y_1|_{k-1}$). Os comportamentos das variáveis controlada e manipulada, para este teste, são expostos nas Figuras 4.23 e 4.24, respectivamente. Além do desempenho do controlador RNA com as duas configurações testadas, nas Figuras 4.23 e 4.24 também é apresentado o desempenho do controlador PID, para efeito de comparação.

Destaca-se a importância da ação *feedback* do controlador RNA, pois, excluindo-se as variáveis de entrada $Y_1|_k$ e $Y_1|_{k-1}$, o controlador não consegue restabelecer o *set point*, sendo gerado um *off-set*.




Figura 4.23 – Comportamento da variável controlada para avaliação da ação *feedback* do controlador RNA, com o sistema perturbado em Y_{N+1}




Figura 4.24 – Comportamento da variável manipulada para avaliação da ação *feedback* do controlador RNA, com o sistema perturbado em Y_{N+1}

Nas Figuras 4.25 e 4.26 são expostos os resultados obtidos quando o sistema sofre uma perturbação de 30% em X_0 . Novamente a ação *feedback* do controlador RNA é imprescindível para o sucesso desta estratégia de controle. Como este tipo de distúrbio não foi incluído na etapa de treinamento da rede, explica-se o fato do controlador RNA não conseguir restabelecer o *set point*, no entanto, na ausência da ação *feedback*, o *off-set* gerado foi muito maior.




Figura 4.25 – Comportamento da variável controlada para avaliação da ação *feedback* do controlador RNA, com o sistema perturbado em X_0




Figura 4.26 – Comportamento da variável manipulada para avaliação da ação *feedback* do controlador RNA, com o sistema perturbado em X_0

4.9 AVALIAÇÃO DA AÇÃO *FEEDFORWARD* DO CONTROLADOR RNA

Visando avaliar a ação *feedforward* do controlador RNA foram realizados testes nos quais inseriram-se perturbações (em Y_{N+1} ou X_0) no sistema e este, sob a monitoração do controlador RNA, teve o comportamento da variável controlada observado. Nestes testes foram utilizadas duas configurações para a rede neural artificial do controlador proposto, sendo uma composta pelas cinco variáveis inicialmente propostas e a outra sendo excluída a variável Y_{N+1} . Para efeito de comparação, também foi realizada uma simulação na qual o sistema se encontrava sob o controle do PID.

A Figura 4.27 demonstra o resultado obtido quando o sistema sofrera uma perturbação degrau de 9,7% em Y_{N+1} . É possível observar que o desempenho do controlador RNA quando excluída a variável de entrada da rede, Y_{N+1} , foi ligeiramente inferior ao desempenho deste controlador com a ação *feedforward* incluída.




Figura 4.27 – Avaliação da ação *feedforward* do controlador RNA, com o sistema perturbado em Y_{N+1}

Na Figura 4.28 é apresentado o resultado obtido quando o sistema sofreu uma perturbação degrau de 20% em X_0 . Novamente o desempenho do controlador RNA com arquitetura de rede na qual foi excluída a variável de entrada Y_{N+1} demonstrou um desempenho inferior à configuração inicialmente proposta. Neste caso a diferença de desempenho demonstrada entre as duas arquiteturas testadas para o controlador RNA foi mais acentuada, pois, com a ação *feedforward* incluída, o *off-set* foi muito menor.




Figura 4.28 – Avaliação da ação *feedforward* do controlador RNA, com o sistema perturbado em X_0

4.10 ALTERAÇÃO DO TEMPO DE AMOSTRAGEM DEVIDO AO TEMPO MORTO NAS MEDIDAS DE COMPOSIÇÃO

Apesar de se tratar de uma simulação, o presente trabalho visa aproximação da realidade. Sendo assim, atualmente não se encontra disponível no mercado um medidor de composição (cromatógrafo gasoso), capaz de fornecer a medida com um tempo de amostragem igual a 3 segundos, conforme requerido pelo controlador. Assim, optou-se por testar o controlador proposto, utilizando-se um tempo de amostragem de 60 segundos, muito superior ao ideal.

4.10.1 TREINAMENTO DA REDE

Um novo treinamento se fez necessário uma vez que os dados disponíveis para tal seriam diferentes dos utilizados até então. Assim, foram construídos dois novos bancos de

dados destinados ao treinamento das redes referentes às duas colunas de absorção estudadas, além de outros dois bancos de dados destinados a validação. Os dados constituintes daqueles conjuntos foram gerados com o auxílio do controlador PID, seguindo o procedimento anteriormente apresentado, respeitando-se as mesmas faixas de operação.

4.10.2 SINTONIA DOS PARÂMETROS DO PID

A sintonia dos parâmetros do PID foi feita por tentativa e erro a partir de uma estimativa inicial. A Figura 4.29 demonstra a diferença de desempenho demonstrada pelo controlador PID operando com os parâmetros inicialmente estimados: $k_c = 1000 \text{ mol/s}$, $\tau_I = 100\text{s}$ e $\tau_D = 20\text{s}$ e com os parâmetros ajustados: $k_c = 70000 \text{ mol/s}$, $\tau_I = 300\text{s}$ e $\tau_D = 30\text{s}$, para a coluna de absorção para recuperação de etanol. Nas duas simulações apresentadas na Figura 4.29 foram inseridas perturbações degrau de 5% na concentração de etanol no gás à entrada da coluna.




Figura 4.29 – Ajuste dos parâmetros para o controlador PID (coluna de recuperação de etanol)

Analogamente a coluna de absorção para recuperação de etanol, foi efetuada a sintonia dos parâmetros do PID para a coluna de tratamento de CO_2 . Analisando-se a

Figura 4.30 é possível notar a melhora de desempenho conseguida com o ajuste dos parâmetros, pois utilizando-se os parâmetros do PID inicialmente estimados pelas equações apresentadas no Capítulo 3 o sistema se torna instável. A estimativa inicial dos parâmetros foi: $k_c = 338,65 \text{ mol/s}$, $\tau_I = 30,8 \text{ s}$ e $\tau_D = 6,72 \text{ s}$ e os melhores valores encontrados para os parâmetros foram: $k_c = 50 \text{ mol/s}$, $\tau_I = 100 \text{ s}$ e $\tau_D = 300 \text{ s}$. Nas simulações foram inseridas perturbações degrau de 2 % na concentração de água no gás à entrada da coluna.




Figura 4.30 – Ajuste dos parâmetros para o controlador PID (coluna de tratamento de CO_2)

4.10.3 DESEMPENHO DOS CONTROLADORES OPERANDO A UM TEMPO DE AMOSTRAGEM SUPERIOR AO IDEAL

Na Figura 4.31 é apresentado o resultado de uma simulação na qual uma perturbação de 7,7 % foi inserida em Y_{N+1} na coluna de recuperação de etanol.




Figura 4.31 – Desempenho dos controladores RNA e PID para um tempo de amostragem superior ao ideal (coluna de recuperação de etanol)

Comparando-se o desempenho do controlador RNA nas situações em que operou com um tempo de amostragem de 3 s (Figura 4.17) e com tempo de amostragem igual a 60 s (Figura 4.31) é possível perceber que na segunda situação, apesar da magnitude da perturbação ser 1 % menor, o *overshoot* apresentado foi maior, atingindo cerca de 207 ppm em comparação aos 201,5 atingidos anteriormente. O tempo de resposta demonstrado pelo controlador RNA nas duas situações foi respectivamente, 125 s e 150 s.

O controlador PID apresentou um desempenho inferior ao demonstrado pelo controlador RNA. Pois, de acordo com a Figura 4.31 o tempo de resposta para o PID foi de aproximadamente 1700 s, apesar do *overshoot* ser equivalente ao apresentado pelo controlador RNA. Esta superioridade do controlador RNA já era esperada, devido a maior capacidade de processamento das redes no tratamento de problemas não lineares, o que é configurado na coluna de absorção de recuperação de etanol.

A Figura 4.32 apresenta o comportamento da variável controlada Y_1' para a coluna de tratamento de CO_2 , para uma situação na qual o tempo de amostragem é de 60 s, e uma perturbação degrau de 2,7 % foi inserida na composição do gás que entra na coluna, Y_{N+1}' .




Figura 4.32 – Desempenho dos controladores RNA e PID para um tempo de amostragem superior ao ideal (coluna de tratamento de CO₂)

Os efeitos da alteração do tempo de amostragem foram sentidos com mais intensidade pelos controladores quando aplicados a coluna de absorção para tratamento do CO₂, conforme demonstrado na Figura 4.32. Neste sentido, o controlador RNA proporcionou um tempo de resposta de aproximadamente 600 s e um *overshoot* de 340 ppm, o que configurou um desempenho inferior ao apresentado quando o tempo de amostragem era de 3s (Figura 4.19). Naquela oportunidade, apesar de uma perturbação de magnitude maior (4,3 %) ter sido implementada, o tempo de resposta foi de 125 s e o *overshoot* 301,5.

Novamente o controlador RNA superou o controlador PID, pois o tempo de resposta apresentado por este foi de aproximadamente 3400 s com *overshoot* de 415 ppm. O melhor desempenho do controlador RNA com relação ao PID superou as expectativas, uma vez que a coluna de absorção para o tratamento do CO₂ é praticamente linear, o que deveria nivelar o sucesso da ação dos controladores.

Na Tabela 4.4 constam os valores da integral do erro absoluto ponderado pelo tempo (ITAE), integral do quadrado do erro (ISE) e integral do erro absoluto (IAE), para os resultados demonstrados nas Figuras 4.31 e 4.32.

Tabela 4.4 – Valores de ITAE, ISE e IAE

ITAE (ppm.s²)	ISE (ppm².s)	IAE (ppm.s)	Controlador	Coluna
4,78E04	1,91E03	3,80E02	RNA	Etanol
3,86E05	2,75E03	1,12E03	PID	
5,35E05	7,45E04	2,96E03	RNA	CO ₂
3,58E07	2,05E06	4,85E04	PID	

Os dados apresentados na Tabela 4.4 refletem o melhor desempenho apresentado pelo controlador RNA frente ao PID, pois para todos os índices usados (ITAE, ISE e IAE) o PID apresentou valores mais elevados.

4.11 PROBLEMA SERVO

Até o momento o controlador RNA foi testado no tratamento do problema regulatório, no entanto, sua aplicação também é possível no problema servo.

4.11.1 CONSTRUÇÃO E TREINAMENTO DAS RNAS PARA O PROBLEMA SERVO

Para a aplicação do controle *feedforward-feedback* baseado em um modelo inverso de redes neurais artificiais no tratamento do problema servo, foi necessário adaptar o programa computacional desenvolvido inicialmente para o tratamento do problema regulatório. As adaptações foram necessárias porque migrando-se do problema regulatório

para o servo a variável distúrbio anteriormente utilizada (concentração de etanol/água no gás à entrada da coluna, Y_{N+1}/Y_{N+1}') passa a ser constante, devendo ser excluída do conjunto de variáveis de entrada da rede neural. A Tabela 4.5 apresenta as variáveis de entrada e saída da rede para o problema servo.

Tabela 4.5 – Variáveis de entrada e saída das redes neurais artificiais para o problema servo

COLUNA DE ABSORÇÃO PARA RECUPERAÇÃO DO ETANOL	
VARIÁVEIS DE ENTRADA	VARIÁVEIS DE SAÍDA
<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo atual ($L_0 _k$) • Concentração de álcool no gás à saída da coluna no instante de tempo atual ($Y_1 _k$) • Concentração de álcool no gás à saída da coluna no instante de tempo anterior ($Y_1 _{k-1}$) • Concentração desejada de álcool no gás à saída da coluna no instante de tempo posterior ($Y_{1sp} _{k+1}$) 	<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo posterior ($L_0 _{k+1}$)
COLUNA DE ABSORÇÃO PARA TRATAMENTO DO CO₂	
VARIÁVEIS DE ENTRADA	VARIÁVEIS DE SAÍDA
<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo atual ($L_0 _k$) • Concentração de água no gás à saída da coluna no instante de tempo atual ($Y_1 _k$) <p>Concentração de água no gás à saída da coluna no instante de tempo anterior ($Y_1 _{k-1}$)</p> <ul style="list-style-type: none"> • Concentração desejada de água no gás à saída da coluna no instante de tempo posterior ($Y_{1sp} _{k+1}$) 	<ul style="list-style-type: none"> • Vazão de solvente no instante de tempo posterior ($L_0 _{k+1}$)

Os conjuntos de dados destinados ao treinamento e validação das redes empregadas no controle das colunas de absorção foram obtidos pelo mesmo procedimento seguido para o problema regulatório. A faixa de variação do *set point* que se propôs trabalhar foi entre -20% e +20%, com incremento de 2%, para as duas colunas.

4.11.2 DETERMINAÇÃO DAS ARQUITETURAS DAS REDES PARA O PROBLEMA SERVO

Diversas arquiteturas de rede foram testadas, tanto para a coluna de recuperação de etanol quanto para a coluna de tratamento de CO₂. A Tabela 4.6 apresenta os valores de SSE (soma dos quadrados dos erros) e MSE (média dos quadrados dos erros) para a coluna de recuperação de etanol. Analisando-se a Tabela 4.6 é possível notar que a partir de 3 neurônios na camada intermediária não há uma mudança significativa nos valores de SSE e MSE.

Tabela 4.6 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação do etanol, problema servo)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE [*]	SSE (mol ² /s ²)	MSE [*]
4 – 1 – 1	1,1600E-02	2,9073E-05	3,7730E-01	1,1791E-03
4 – 2 – 1	1,9451E-05	4,8749E-08	8,5000E-04	2,6563E-06
4 – 3 – 1	9,9981E-07	2,5058E-09	2,5986E-05	8,1206E-08
4 – 4 – 1	9,9232E-07	2,4870E-09	2,7363E-05	8,5509E-08
4 – 5 – 1	9,5226E-07	2,3866E-09	2,5255E-05	7,8922E-08
4 – 6 – 1	9,9972E-07	2,5056E-09	2,8540E-05	8,9188E-08
4 – 7 – 1	9,3419E-07	2,3413E-09	2,8046E-05	8,7644E-08

Continuação da Tabela 4.6

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
4 – 8 – 1	9,8087E-07	2,4583E-09	2,1074E-05	6,5856E-08
4 – 9 – 1	8,9082E-07	2,2326E-09	2,5560E-05	7,9875E-08
4 – 10 – 1	8,0204E-07	2,0101E-09	2,3952E-05	7,4850E-08
4 – 11 – 1	9,1963E-07	2,3048E-09	3,2146E-05	9,3171E-08
4 – 12 – 1	9,9023E-07	2,4818E-09	2,3143E-05	7,2322E-08
4 – 13 – 1	9,4893E-07	2,3783E-09	3,0384E-05	9,4950E-08
4 – 14 – 1	9,7404E-07	2,1881E-09	2,3161E-05	7,5988E-08
4 – 15 – 1	9,5709E-07	2,3987E-09	3,0274E-05	9,4606E-08
4 – 11 – 11 – 1	9,8163E-07	2,4602E-09	2,9666E-05	9,2706E-08
4 – 12 – 12 – 1	9,8344E-07	2,4648E-09	2,6554E-05	8,2981E-08

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

Para o problema servo, coluna de recuperação de etanol, o comportamento do número de parâmetros efetivamente utilizados pela rede (γ) e do número de parâmetros totais (N'), em relação ao número de neurônios na camada intermediária, é demonstrado na Figura 4.33. A partir de 6 neurônios na camada intermediária o aumento de N' , obtido pelo aumento de neurônios na camada intermediária, não é acompanhado por um aumento significativo de γ .




Figura 4.33 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema servo)

Sendo assim, seguindo o critério de FORESSE e HAGAN (1997) e a avaliação da variação dos valores de SSE e MSE com relação à estrutura da rede, optou-se por utilizar uma arquitetura igual a 4 – 6 – 1.

A seguir (Tabela 4.7) são apresentados os valores de SSE e MSE para a coluna de tratamento de CO₂, para o problema servo. A partir de 6 neurônios na camada intermediária, os valores de SSE e MSE não variam significativamente.

Tabela 4.7 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento de CO₂, problema servo)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE*	SSE (mol²/s²)	MSE*
4 – 2 – 1	2,2000E-03	8,7302E-06	7,4978E-07	4,9985E-09
4 – 4 – 1	4,3886E-06	1,7415E-08	2,2023E-09	1,4682E-11
4 – 6 – 1	9,9936E-07	3,9657E-09	5,1971E-10	3,4647E-12
4 – 8 – 1	9,9804E-07	3,9605E-09	4,7366E-10	3,1577E-12
4 – 10 – 1	9,9679E-07	3,9555E-09	4,5416E-10	3,0277E-12
4 – 12 – 1	9,9251E-07	3,9385E-09	4,8265E-10	3,2177E-12
4 – 14 – 1	9,9866E-07	3,9629E-09	4,6767E-10	3,1178E-12
4 – 16 – 1	9,9380E-07	3,9437E-09	5,0054E-10	3,3369E-12
4 – 18 – 1	9,9371E-07	3,9433E-09	4,8655E-10	3,2437E-12
4 – 20 – 1	9,9354E-07	3,9426E-09	4,5875E-10	3,0583E-12

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

A Figura 4.34 demonstra o comportamento do número de parâmetros efetivamente utilizados pela rede (γ) e do número de parâmetros totais (N'), em relação ao número de neurônios na camada intermediária, para a coluna de tratamento de CO₂, problema servo.




Figura 4.34 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema servo)

Com base na Figura 4.34 é possível concluir que a partir 6 neurônios na camada intermediária, o número de parâmetros efetivamente utilizados pela rede não acompanha o aumento do número total de parâmetros. Deste modo, seguindo novamente o critério de FORESSE e HAGAN (1997) em paralelo com a análise dos valores de SSE e MSE da Tabela 07, definiu-se a arquitetura da rede para a coluna de tratamento de CO₂, para o problema servo, como sendo 4 – 6 – 1.

4.11.3 SINTONIA DOS PARÂMETROS DO PID PARA O PROBLEMA SERVO

Uma nova sintonia dos parâmetros do PID foi feita para que este pudesse exercer seu melhor desempenho no tratamento do problema servo. Assim, partindo-se de uma estimativa inicial, foram determinados os melhores valores dos parâmetros do controlador através de tentativa e erro.

A Figura 4.35 apresenta o desempenho do controlador PID para a coluna de recuperação de etanol, para uma simulação onde fora inserida uma perturbação degrau de

12% no *set point*, ressalta-se o ganho de desempenho devido ao ajuste dos parâmetros. Os valores dos parâmetros foram inicialmente estimados em $k_c = 1000 \text{ mol/s}$, $\tau_I = 100\text{s}$ e $\tau_D = 20\text{s}$, porém o PID apresentou melhor desempenho quando os parâmetros assumiram valores iguais a: $k_c = 70000 \text{ mol/s}$, $\tau_I = 100\text{s}$ e $\tau_D = 10\text{s}$.




Figura 4.35 – Ajuste dos parâmetros para o controlador PID para o problema servo (coluna de recuperação de etanol)

Para a coluna de tratamento do CO_2 , novamente o sistema se mostrou mais sensível às alterações nos parâmetros do PID. A Figura 4.36 demonstra a diferença de desempenho do PID entre uma simulação com os parâmetros inicialmente estimados: $k_c = 209,77 \text{ mol/s}$, $\tau_I = 102,85\text{s}$ e $\tau_D = 5,99\text{s}$, e outra com os melhores valores encontrados para os parâmetros: $k_c = 275 \text{ mol/s}$, $\tau_I = 200\text{s}$ e $\tau_D = 50\text{s}$. Em ambas as simulações foram inseridas perturbações degrau da ordem de 12% na concentração de água residual na corrente gasosa à entrada da coluna.




Figura 4.36 – Ajuste dos parâmetros para o controlador PID para o problema servo (coluna de tratamento do CO₂)

4.11.4 DESEMPENHO DO CONTROLADOR RNA PARA O PROBLEMA SERVO

A Figura 4.37 demonstra o comportamento da concentração de álcool no gás à saída da coluna de absorção para recuperação de etanol quando uma perturbação degrau de 13,7% fora inserida no *set point*. Nota-se que o controlador RNA proporcionou um tempo de resposta de aproximadamente 150s, sem a presença de *overshoot*, enquanto que o controlador PID propiciou um tempo de resposta de cerca de 1050s e um *overshoot* de 237ppm. Novamente o controlador RNA confirmou a maior capacidade de tratamento de problemas não lineares.




Figura 4.37 – Desempenho dos controladores RNA e PID para o problema servo (coluna de recuperação de etanol)

A Figura 4.38 apresenta o comportamento da variável manipulada, vinculado ao resultado demonstrado na Figura 4.37.




Figura 4.38 – Comportamento da variável manipulada para o problema servo (coluna de recuperação de etanol)

Para a coluna de absorção destinada ao tratamento do CO_2 , o desempenho do controlador RNA mais uma vez foi superior ao apresentado pelo PID, quando uma perturbação degrau de magnitude igual a 12,8% fora inserida no *set point*. De acordo com a Figura 4.39 o comportamento da variável controlada não apresentou *overshoot* quando utilizado o controlador RNA, ao contrário do PID que proporcionou um *overshoot* de aproximadamente 395ppm. Além disso, o tempo de resposta do controlador RNA foi muito menor quando comparado ao PID, 180s e 750s, respectivamente. O comportamento da variável manipulada é apresentado na Figura 4.40.




Figura 4.39 – Desempenho dos controladores RNA e PID para o problema servo (coluna de tratamento do CO_2)




Figura 4.40 – Comportamento da variável manipulada para o problema servo (coluna de tratamento do CO₂)

Na Tabela 4.8 são apresentados os valores de ITAE, ISE e IAE vinculados aos resultados apresentados nas Figuras 4.37 e 4.39, os quais confirmam o melhor desempenho do controlador RNA também no tratamento do problema servo.

Tabela 4.8 – Valores de ITAE, ISE e IAE para o problema servo

ITAE (ppm.s²)	ISE (ppm².s)	IAE (ppm.s)	Controlador	Coluna
8,84E04	5,20E04	2,09E03	RNA	Etanol
6,69E05	6,65E04	4,21E03	PID	
1,83E05	1,20E05	3,57E03	RNA	CO ₂
5,45E05	2,64E05	9,30E03	PID	

4.12. INSERÇÃO DA INCERTEZA DOS SENSORES

Para analisar a influência das incertezas de medição no desempenho dos controladores testados, uma vez que os dados destinados a alimentação do sistema de controle diferem dos reais, foi agregado um percentual de incerteza nas medidas de concentração das correntes gasosas, conforme procedimento apresentado no item 3.4.

Três níveis de incerteza foram testados: 5%, 10% e 15%. Inicialmente, foram gerados os dados para o treinamento e validação das redes neurais artificiais para as duas colunas estudadas, tanto para o problema regulatório quanto para o problema servo. Uma nova sintonia dos parâmetros do controlador PID também foi feita.

Depois de definir as arquiteturas de rede, foi possível realizar simulações nas quais os desempenhos dos controladores RNA e PID foram avaliados.

4.12.1 DETERMINAÇÃO DA ARQUITETURA DE REDE

Foi testada uma grande variedade de arquiteturas para as redes destinadas ao controle das colunas de absorção de recuperação de etanol e de tratamento do CO₂, problema regulatório.

As Tabelas 4.9, 4.10 e 4.11 apresentam os valores de SSE e MSE para a coluna de recuperação de etanol, os quais foram obtidos nos testes para os níveis de incerteza nos sensores de 5%, 10% e 15%, respectivamente. Nota-se que os dados demonstrados nas Tabelas 4.9, 4.10 e 4.11 demonstram que SSE e MSE se mantêm praticamente constantes com relação às alterações nas arquiteturas de rede.

Tabela 4.9 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema regulatório, sistema com 5% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 1 - 1	2,1022	1,7562E-03	51,8762	9,1011E-02
5 - 2 - 1	2,0882	1,7445E-03	51,6223	9,0565E-02
5 - 3 - 1	2,0825	1,7398E-03	51,5548	9,0447E-02
5 - 4 - 1	2,0815	1,7389E-03	51,3833	9,0146E-02
5 - 5 - 1	2,0832	1,7404E-03	51,3418	9,0073E-02
5 - 6 - 1	2,0816	1,7390E-03	51,2824	8,9969E-02
5 - 7 - 1	2,0835	1,7406E-03	51,3391	9,0069E-02
5 - 8 - 1	2,0818	1,7392E-03	51,3213	9,0037E-02
5 - 9 - 1	2,0816	1,7390E-03	51,3154	9,0027E-02
5 - 10 - 1	2,0814	1,7388E-03	51,3120	9,0021E-02
5 - 11 - 1	2,0811	1,7386E-03	51,3032	9,0006E-02
5 - 12 - 1	2,0809	1,7384E-03	51,2953	8,9992E-02
5 - 13 - 1	2,0807	1,7383E-03	51,2898	8,9982E-02
5 - 14 - 1	2,0806	1,7382E-03	51,2850	8,9974E-02
5 - 15 - 1	2,0805	1,7381E-03	51,2807	8,9966E-02
5 - 16 - 1	2,0802	1,7378E-03	51,2723	8,9951E-02
5 - 17 - 1	2,0803	1,7379E-03	51,2738	8,9954E-02

Continuação da Tabela 4.9

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 18 - 1	2,0800	1,7377E-03	51,2640	8,9937E-02
5 - 19 - 1	2,0799	1,7376E-03	51,2605	8,9931E-02
5 - 20 - 1	2,0847	1,7416E-03	51,4149	9,0202E-02
5 - 11 - 11 - 1	2,0803	1,7379E-03	51,2776	8,9961E-02
5 - 12 - 12 - 1	2,0803	1,7379E-03	51,2796	8,9964E-02

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

Tabela 4.10 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema regulatório, sistema com 10% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 1 - 1	0,1246	1,0409E-04	22,8197	4,0035E-02
5 - 2 - 1	0,1234	1,0309E-04	23,2075	4,0715E-02
5 - 3 - 1	0,1230	1,0276E-04	22,8486	4,0085E-02
5 - 4 - 1	0,1222	1,0209E-04	22,8372	4,0065E-02
5 - 5 - 1	0,1214	1,0142E-04	22,7873	3,9978E-02
5 - 6 - 1	0,1206	1,0075E-04	22,8654	4,0115E-02
5 - 7 - 1	0,1206	1,0075E-04	22,8959	4,0168E-02

Continuação da Tabela 4.10

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE[*]	SSE (mol²/s²)	MSE[*]
5 - 8 - 1	0,1206	1,0075E-04	22,9059	4,0186E-02
5 - 9 - 1	0,1206	1,0075E-04	22,9116	4,0196E-02
5 - 10 - 1	0,1206	1,0075E-04	22,9160	4,0204E-02
5 - 11 - 1	0,1206	1,0075E-04	22,9195	4,0210E-02
5 - 12 - 1	0,1206	1,0075E-04	22,9224	4,0215E-02
5 - 13 - 1	0,1206	1,0075E-04	22,9249	4,0219E-02
5 - 14 - 1	0,1206	1,0075E-04	22,9269	4,0223E-02
5 - 15 - 1	0,1215	1,0150E-04	22,6031	3,9655E-02
5 - 16 - 1	0,1215	1,0150E-04	22,6036	3,9655E-02
5 - 17 - 1	0,1215	1,0150E-04	22,6039	3,9656E-02
5 - 18 - 1	0,1215	1,0150E-04	22,6043	3,9657E-02
5 - 19 - 1	0,1215	1,0150E-04	22,6046	3,9657E-02
5 - 20 - 1	0,1217	1,0167E-04	22,6755	3,9782E-02
5 - 11 - 11 - 1	0,1204	1,0058E-04	22,4339	3,9358E-02
5 - 12 - 12 - 1	0,1204	1,0058E-04	22,4312	3,9353E-02

^{*} mol²/([s²] . [nº de dados entradas-saída] . [nº de neurônios na camada de saída])

Tabela 4.11 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema regulatório, sistema com 15% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 1 - 1	0,5674	4,7402E-04	1,4551E+02	2,5528E-01
5 - 2 - 1	0,5667	4,7343E-04	1,4655E+02	2,5710E-01
5 - 3 - 1	0,5639	4,7109E-04	1,4615E+02	2,5640E-01
5 - 4 - 1	0,5616	4,6917E-04	1,4577E+02	2,5574E-01
5 - 5 - 1	0,5589	4,6692E-04	1,4494E+02	2,5428E-01
5 - 6 - 1	0,5350	4,4695E-04	1,4097E+02	2,4732E-01
5 - 7 - 1	0,5347	4,4670E-04	1,4073E+02	2,4689E-01
5 - 8 - 1	0,5348	4,4678E-04	1,4071E+02	2,4687E-01
5 - 9 - 1	0,5348	4,4678E-04	1,4071E+02	2,4686E-01
5 - 10 - 1	0,5348	4,4678E-04	1,4071E+02	2,4686E-01
5 - 11 - 1	0,5332	4,4545E-04	1,4064E+02	2,4673E-01
5 - 12 - 1	0,5348	4,4678E-04	1,4071E+02	2,4685E-01
5 - 13 - 1	0,5334	4,4561E-04	1,4051E+02	2,4651E-01
5 - 14 - 1	0,5332	4,4545E-04	1,4062E+02	2,4670E-01
5 - 15 - 1	0,5332	4,4545E-04	1,4062E+02	2,4669E-01
5 - 16 - 1	0,5334	4,4561E-04	1,4049E+02	2,4647E-01
5 - 17 - 1	0,5331	4,4536E-04	1,4061E+02	2,4669E-01

Continuação da Tabela 4.11

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 18 - 1	0,5334	4,4561E-04	1,4048E+02	2,4646E-01
5 - 19 - 1	0,5331	4,4536E-04	1,4061E+02	2,4669E-01
5 - 20 - 1	0,5334	4,4561E-04	1,4048E+02	2,4646E-01
5 - 11 - 11 - 1	0,5070	4,2356E-04	1,4130E+02	2,4789E-01
5 - 12 - 12 - 1	0,5131	4,2865E-04	1,3903E+02	2,4392E-01

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

As Figuras 4.41, 4.42 e 4.43 demonstram, para os três níveis de incerteza testados, o comportamento do número de parâmetros efetivamente utilizados pelas redes (γ) e do número de parâmetros totais (N°), em relação ao número de neurônios na camada intermediária, para a coluna recuperação de etanol, problema regulatório.




Figura 4.41 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema regulatório, 5% de incerteza)




Figura 4.42 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema regulatório, 10% de incerteza)




Figura 4.43 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema regulatório, 15% de incerteza)

Observando-se as Figuras 4.41, 4.42 e 4.43 é possível perceber que o comportamento apresentado para o número de parâmetros efetivamente utilizados pela rede (γ) em relação ao número total de parâmetros (N') é semelhante para os três níveis de incerteza testados. A partir de 6 neurônios na camada intermediária, não há uma variação significativa de γ quando o valor de N' aumenta.

Assim, seguindo o critério de FORESSE E HAGAN (1997), em paralelo com a análise dos dados apresentados nas Tabelas 4.9, 4.10 e 4.11, optou-se por utilizar uma arquitetura de rede igual a 5 – 6 – 1 para a RNA destinada ao controle da coluna de recuperação de etanol, para o problema regulatório.

As Tabelas 4.12, 4.13 e 4.14 apresentam os valores de SSE e MSE para a coluna de tratamento de CO_2 , os quais foram obtidos nos testes para os níveis de incerteza nos sensores de 5%, 10% e 15%, respectivamente. Analogamente aos resultados demonstrados pela coluna de recuperação de etanol, os dados contidos nas Tabelas 4.12, 4.13 e 4.14

demonstram que SSE e MSE não variam significativamente com as alterações feitas nas arquiteturas de rede, para os três níveis de incerteza testados.

Tabela 4.12 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO₂, problema regulatório, sistema com 5% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 6 - 1	0,3152	2,1753E-04	0,0238	7,4375E-05
5 - 8 - 1	0,3008	2,0759E-04	0,0238	7,4375E-05
5 - 10 - 1	0,2958	2,0414E-04	0,0244	7,6250E-05
5 - 12 - 1	0,3003	2,0725E-04	0,0230	7,1875E-05
5 - 14 - 1	0,2867	1,9786E-04	0,0242	7,5625E-05
5 - 16 - 1	0,2878	1,9862E-04	0,0231	7,2188E-05
5 - 18 - 1	0,2847	1,9648E-04	0,0234	7,3125E-05
5 - 20 - 1	0,2750	1,8979E-04	0,0234	7,3125E-05
5 - 22 - 1	0,2742	1,8923E-04	0,0232	7,2500E-05
5 - 24 - 1	0,2688	1,8551E-04	0,0245	7,6563E-05
5 - 25 - 1	0,2657	1,8337E-04	0,0235	7,3438E-05
5 - 26 - 1	0,2647	1,8268E-04	0,0232	7,2500E-05
5 - 27 - 1	0,2707	1,8682E-04	0,0225	7,0313E-05
5 - 28 - 1	0,2628	1,8137E-04	0,0237	7,4063E-05

Continuação da Tabela 4.12

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE*	SSE (mol²/s²)	MSE*
5 - 29 - 1	0,2683	1,8516E-04	0,0227	7,0938E-05
5 - 30 - 1	0,2643	1,8240E-04	0,0227	7,0938E-05
5 - 40 - 1	0,2672	1,8440E-04	0,0228	7,1250E-05

* mol²/([s²] . [n° de dados entradas-saída] . [n° de neurônios na camada de saída])

Tabela 4.13 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO₂, problema regulatório, sistema com 10% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE*	SSE (mol²/s²)	MSE*
5 - 6 - 1	2,4400E-02	4,6476E-05	2,8600E-02	1,1172E-04
5 - 8 - 1	2,3800E-02	4,5333E-05	2,9600E-02	1,1563E-04
5 - 10 - 1	2,1200E-02	4,0381E-05	3,2800E-02	1,2813E-04
5 - 12 - 1	2,1100E-02	4,0190E-05	2,8500E-02	1,1133E-04
5 - 13 - 1	2,0100E-02	3,8286E-05	3,0200E-02	1,1797E-04
5 - 14 - 1	2,0300E-02	3,8667E-05	2,9000E-02	1,1328E-04
5 - 16 - 1	2,0000E-02	3,8095E-05	2,7900E-02	1,0898E-04
5 - 18 - 1	1,9900E-02	3,7905E-05	2,9100E-02	1,1367E-04
5 - 20 - 1	2,0100E-02	3,8286E-05	2,7900E-02	1,0898E-04

Continuação da Tabela 4.13

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 22 - 1	2,0300E-02	3,8667E-05	2,8100E-02	1,0977E-04
5 - 24 - 1	1,9900E-02	3,7905E-05	3,0300E-02	1,1836E-04

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

Tabela 4.14 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO_2 , problema regulatório, sistema com 15% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 6 - 1	0,2354	3,5030E-04	0,0347	2,5704E-04
5 - 8 - 1	0,2060	3,0655E-04	0,0393	2,9111E-04
5 - 10 - 1	0,1793	2,6682E-04	0,0614	4,5481E-04
5 - 12 - 1	0,1728	2,5714E-04	0,0590	4,3704E-04
5 - 14 - 1	0,1517	2,2574E-04	0,0599	4,4370E-04
5 - 16 - 1	0,1309	1,9479E-04	0,0730	5,4074E-04
5 - 18 - 1	0,1250	1,8601E-04	0,0900	6,6667E-04
5 - 20 - 1	0,1047	1,5580E-04	0,0919	6,8074E-04
5 - 22 - 1	0,0933	1,3884E-04	0,5075	3,7593E-03
5 - 24 - 1	0,0925	1,3765E-04	0,1409	1,0437E-03

Continuação da Tabela 4.14

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol²/s²)	MSE[*]	SSE (mol²/s²)	MSE[*]
5 - 26 - 1	0,0785	1,1680E-04	0,3283	2,4319E-03
5 - 28 - 1	0,0778	1,1577E-04	0,0710	5,2593E-04
5 - 30 - 1	0,0648	9,6429E-05	0,2207	1,6348E-03
5 - 40 - 1	0,0393	5,8482E-05	0,2011	1,4896E-03
5 - 50 - 1	0,0278	4,1369E-05	0,5345	3,9593E-03

^{*} mol²/([s²] . [nº de dados entradas-saída] . [nº de neurônios na camada de saída])

As Figuras 4.44, 4.45 e 4.46 demonstram, para os três níveis de incerteza testados, o comportamento γ e de N' , em relação ao número de neurônios na camada intermediária, para a coluna de tratamento de CO₂, problema regulatório. Para 5% de incerteza (Figura 4.44), a partir de 26 neurônios na camada intermediária γ passa a não acompanhar o incremento de N' . Este comportamento é atingido a partir de 13 neurônios na camada intermediária para a situação na qual o nível de incerteza é de 10% (Figura 4.45). Já para 15% de incerteza, o sistema não segue o critério de FORESSE E HAGAN (1997), ou seja, o valor de γ continua crescendo de acordo com o incremento de N' .




Figura 4.44 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema regulatório, 5% de incerteza)




Figura 4.45 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema regulatório, 10% de incerteza)




Figura 4.46 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema regulatório, 15% de incerteza)

Com base nos dados apresentados nas Tabelas 4.12, 4.13 e 4.14, e avaliando-se o comportamento de γ com relação ao aumento de N' (Figuras 4.45, 4.46 e 4.47) optou-se por utilizar uma arquitetura de 5 – 26 – 1 para a RNA destinada ao controle da coluna de tratamento do CO₂, problema regulatório.

Analogamente ao problema regulatório, várias arquiteturas de rede foram testadas para as colunas de absorção estudadas. Analisando-se os valores obtidos de SSE e MSE, assim como seguindo o critério de FORESSE E HAGAN (1997) foi possível determinar as melhores estruturas para as redes destinadas ao controle das colunas de absorção, para o problema servo.

As Tabelas 4.15, 4.16 e 4.17 apresentam os valores de SSE e MSE para a coluna de recuperação de etanol, os quais foram obtidos nos testes para o problema servo, avaliando-se os níveis de incerteza nos sensores: 5%, 10% e 15%, respectivamente. Assim

como para o problema regulatório, os valores de SSE e MSE não variam significativamente com as alterações na estrutura da rede.

Tabela 4.15 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema servo, sistema com 5% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 2 - 1	0,9103	9,0308E-04	54,7308	0,1140
5 - 4 - 1	0,8789	8,7192E-04	53,6683	0,1118
5 - 6 - 1	0,8935	8,8641E-04	54,4781	0,1135
5 - 8 - 1	0,8933	8,8621E-04	54,4577	0,1135
5 - 10 - 1	0,8716	8,6468E-04	53,9575	0,1124
5 - 12 - 1	0,8734	8,6647E-04	53,9936	0,1125
5 - 14 - 1	0,8933	8,8621E-04	54,4494	0,1134
5 - 16 - 1	0,8934	8,8631E-04	54,4487	0,1134
5 - 18 - 1	0,8934	8,8631E-04	54,4483	0,1134
5 - 20 - 1	0,8988	8,9167E-04	54,4671	0,1135

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

Tabela 4.16 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema servo, sistema com 10% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 2 - 1	1,3681	1,3572E-03	177,8105	0,3704
5 - 4 - 1	1,3217	1,3112E-03	175,7426	0,3661
5 - 6 - 1	1,3309	1,3203E-03	172,1927	0,3587
5 - 8 - 1	1,3297	1,3191E-03	171,9992	0,3583
5 - 10 - 1	1,3283	1,3178E-03	172,1599	0,3587
5 - 12 - 1	1,3025	1,2922E-03	176,5568	0,3678
5 - 14 - 1	1,3027	1,2924E-03	176,4795	0,3677
5 - 16 - 1	1,3028	1,2925E-03	176,4220	0,3675
5 - 18 - 1	1,3122	1,3018E-03	173,2024	0,3608
5 - 20 - 1	1,3030	1,2927E-03	176,3413	0,3674

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

Tabela 4.17 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para recuperação de etanol, problema servo, sistema com 15% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol^2/s^2)	MSE*	SSE (mol^2/s^2)	MSE*
5 - 2 - 1	1,6723	1,6590E-03	429,1671	0,8941
5 - 4 - 1	1,6031	1,5904E-03	398,4902	0,8302
5 - 6 - 1	1,5608	1,5484E-03	403,1689	0,8399
5 - 8 - 1	1,5602	1,5478E-03	402,5756	0,8387
5 - 10 - 1	1,5688	1,5563E-03	389,8280	0,8121
5 - 12 - 1	1,5663	1,5539E-03	406,0190	0,8459
5 - 14 - 1	1,5519	1,5396E-03	400,7519	0,8349
5 - 16 - 1	1,5663	1,5539E-03	405,9946	0,8458
5 - 18 - 1	1,5519	1,5396E-03	400,7519	0,8349
5 - 20 - 1	1,5135	1,5015E-03	419,7276	0,8744

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

As Figuras 4.47, 4.48 e 4.49 demonstram, para os três níveis de incerteza testados, o comportamento γ e de N' , em relação ao número de neurônios na camada intermediária, para a coluna de recuperação de etanol, problema servo. Nota-se que para todos os níveis de incerteza testados, a partir de 6 neurônios na camada intermediária, não há um aumento significativo no valor de γ quando N' sofre um incremento.




Figura 4.47 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema servo, 5% de incerteza)




Figura 4.48 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema servo, 10% de incerteza)




Figura 4.49 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para recuperação de etanol, problema servo, 15% de incerteza)

Avaliando-se os dados apresentados nas Tabelas 4.15, 4.16 e 4.17 e mais uma vez seguindo o critério de FORESSE E HAGAN (1997), optou-se por utilizar uma estrutura de rede igual a 5 – 6 – 1, para o tratamento do problema servo, na coluna de recuperação de etanol.

A seguir, as Tabelas 4.18, 4.19 e 4.20 demonstram os valores de SSE e MSE obtidos nos testes para o problema servo, na coluna de tratamento do CO₂, sendo avaliados os três níveis de incerteza, 5%, 10% e 15%, respectivamente. Nota-se que para uma configuração na qual as incertezas nos sensores foram incluídas ao nível de 5%, os valores de SSE e MSE não variam significativamente com o aumento de neurônios na camada intermediária da RNA. Já para os testes feitos com incertezas aos níveis de 10% e 15%, os valores de SSE e MSE diminuem gradativamente, embora a uma pequena taxa, de acordo com o aumento da estrutura da rede.

Tabela 4.18 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO₂, problema servo, sistema com 5% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 2 - 1	0,2346	2,3274E-04	0,0119	6,6111E-05
5 - 4 - 1	0,1563	1,5506E-04	0,0083	4,6111E-05
5 - 6 - 1	0,1526	1,5139E-04	0,0082	4,5556E-05
5 - 8 - 1	0,1494	1,4821E-04	0,0079	4,3889E-05
5 - 10 - 1	0,1493	1,4812E-04	0,0079	4,3889E-05
5 - 12 - 1	0,1493	1,4812E-04	0,0079	4,3889E-05
5 - 14 - 1	0,1493	1,4812E-04	0,0079	4,3889E-05
5 - 16 - 1	0,1493	1,4812E-04	0,0079	4,3889E-05
5 - 18 - 1	0,1472	1,4603E-04	0,0080	4,4444E-05
5 - 20 - 1	0,1498	1,4861E-04	0,0082	4,5556E-05

* mol²/([s²] . [nº de dados entradas-saída] . [nº de neurônios na camada de saída])

Tabela 4.19 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO₂, problema servo, sistema com 10% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 2 - 1	0,1860	2,7679E-04	0,0540	2,7000E-04
5 - 4 - 1	0,1100	1,6369E-04	0,0412	2,0600E-04
5 - 6 - 1	0,0893	1,3289E-04	0,0454	2,2700E-04
5 - 8 - 1	0,0854	1,2708E-04	0,0469	2,3450E-04
5 - 10 - 1	0,0812	1,2083E-04	0,0492	2,4600E-04
5 - 12 - 1	0,0800	1,1905E-04	0,0519	2,5950E-04
5 - 14 - 1	0,0776	1,1548E-04	0,0502	2,5100E-04
5 - 16 - 1	0,0733	1,0908E-04	0,0620	3,1000E-04
5 - 18 - 1	0,0786	1,1696E-04	0,0507	2,5350E-04
5 - 20 - 1	0,0734	1,0923E-04	0,1321	6,6050E-04

* mol²/([s²] . [nº de dados entradas-saída] . [nº de neurônios na camada de saída])

Tabela 4.20 – SSE e MSE para diferentes estruturas de rede (Coluna de absorção para tratamento do CO₂, problema servo, sistema com 15% de incerteza)

Estrutura	Conjunto de Treinamento		Conjunto de Validação	
	SSE (mol ² /s ²)	MSE*	SSE (mol ² /s ²)	MSE*
5 - 2 - 1	0,1100	2,6190E-04	3,6710	1,8355E-02
5 - 4 - 1	0,0765	1,8214E-04	8,1841	4,0921E-02
5 - 6 - 1	0,0459	1,0929E-04	8,6827	4,3414E-02
5 - 8 - 1	0,0489	1,1643E-04	4,5721	2,2861E-02
5 - 10 - 1	0,0340	8,0952E-05	11,1908	5,5954E-02
5 - 12 - 1	0,0361	8,5952E-05	10,2773	5,1387E-02
5 - 14 - 1	0,0313	7,4524E-05	10,6179	5,3090E-02
5 - 16 - 1	0,0261	6,2143E-05	12,3023	6,1512E-02
5 - 18 - 1	0,0247	5,8810E-05	7,6476	3,8238E-02
5 - 20 - 1	0,0249	5,9286E-05	7,7932	3,8966E-02

* $\text{mol}^2/([\text{s}^2] \cdot [\text{n}^\circ \text{ de dados entradas-saída}] \cdot [\text{n}^\circ \text{ de neurônios na camada de saída}])$

As Figuras 4.50, 4.51 e 4.52 demonstram, para os três níveis de incerteza testados, o comportamento γ e de N' , em relação ao número de neurônios na camada intermediária, para a coluna de tratamento do CO₂, problema servo. Para 5% de incerteza, a partir de 8 neurônios na camada intermediária, o valor de γ se estabiliza com relação ao aumento do valor de N' . Entretanto, para os níveis de incerteza de 10% e 15% este comportamento não é demonstrado, sendo que o valor de γ continua aumentando de acordo com o incremento de N' .




Figura 4.50 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema servo, 5% de incerteza)




Figura 4.51 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema servo, 10% de incerteza)




Figura 4.52 – Número de parâmetros totais e efetivos em relação ao número de neurônios na camada intermediária (Coluna de absorção para tratamento do CO₂, problema servo, 15% de incerteza)

Fazendo uso dos dados demonstrados na Tabelas 4.18, 4.19 e 4.20 e mais uma vez seguindo o critério de FORESSE E HAGAN (1997) optou-se por utilizar uma estrutura de 5 – 8 – 1 para a RNA destinada ao controle da coluna de absorção para tratamento do CO₂, para o problema servo.

4.12.2 PARÂMETROS DO PID PARA O SISTEMA OPERANDO SOB A INFLUÊNCIA DAS INCERTEZAS NOS SENSORES

Devido as dificuldades para realizar uma nova sintonia dos parâmetros do PID para o sistema operando sob a influência das incertezas nos sensores, foram utilizados os valores obtidos na sintonia para o sistema sem incertezas, para os três níveis de incerteza testados: 5%, 10% e 15%, tanto para o problema regulatório quanto para o servo.

4.12.3 DESEMPENHO DO CONTROLADOR RNA FRENTE ÀS INCERTEZAS NOS SENSORES

As Figuras 4.53, 4.54 e 4.55 demonstram o comportamento da variável controlada nas simulações em que o sistema de controle operou com um nível de incerteza de 5%, 10% e 15%, respectivamente. Estes resultados correspondem ao problema regulatório, para a coluna de recuperação de etanol, onde para cada teste realizado foi inserida uma perturbação degrau de 7,7% na concentração de etanol no gás à entrada da coluna. Nota-se que nenhum dos dois controladores testados conseguiu estabilizar a variável controlada no *set point*, no entanto, quando o controlador RNA foi utilizado, a faixa de oscilação de Y_1 se mostrou com menor amplitude.




Figura 4.53 – Comportamento da variável controlada (coluna de recuperação de etanol, problema regulatório, 5% de incerteza)




Figura 4.54 – Comportamento da variável controlada (coluna de recuperação de etanol, problema regulatório, 10% de incerteza)




Figura 4.55 – Comportamento da variável controlada (coluna de recuperação de etanol, problema regulatório, 15% de incerteza)

A seguir, também para o problema regulatório, são apresentados os resultados obtidos para a coluna de tratamento do CO₂. O comportamento da variável controlada Y_1' , para os três níveis de incerteza testados, quando uma perturbação degrau de 2,7% é inserida em Y_{N+1}' é, portanto demonstrado nas Figuras 4.56, 4.57 e 4.58. Nota-se que para 5% de incerteza, novamente o controlador RNA proporcionou uma menor oscilação da variável controlada. Para os outros dois níveis de incerteza testados: 10% e 15% os controladores tiveram maiores dificuldades em estabelecer o controle do sistema, sendo que para 10% de incerteza, o controlador PID não conseguiu estabilizar o sistema, ao contrário do controlador RNA, e para 15% de incerteza nenhum controlador apresentou um desempenho satisfatório.




Figura 4.56 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema regulatório, 5% de incerteza)




Figura 4.57 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema regulatório, 10% de incerteza)




Figura 4.58 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema regulatório, 15% de incerteza)

Nas Figuras 4.59, 4.60 e 4.61 são demonstrados os resultados obtidos, agora para o problema servo, na coluna de recuperação de etanol. Nestas simulações uma perturbação degrau de 13,7% foi inserida no *set point*. Nota-se que mais uma vez o controlador RNA superou o controlador PID, proporcionando uma oscilação menor para a variável controlada, para todos os níveis de incerteza testados.




Figura 4.59 – Comportamento da variável controlada (coluna de recuperação de etanol, problema servo, 5% de incerteza)




Figura 4.60 – Comportamento da variável controlada (coluna de recuperação de etanol, problema servo, 10% de incerteza)




Figura 4.61 – Comportamento da variável controlada (coluna de recuperação de etanol, problema servo, 15% de incerteza)

As Figuras 4.62, 4.63 e 4.64 demonstram os resultados obtidos para o problema servo, agora para a coluna de tratamento do CO₂. Nestas simulações uma perturbação degrau de 12,8% foi inserida no *set point*. Nota-se que para 5% de incerteza o controlador RNA continua proporcionando uma menor oscilação da variável controlada. Mais uma vez, para níveis maiores de incerteza (10% e 15%) os controladores encontram dificuldades em estabilizar o sistema, sendo que para o controlador RNA esta dificuldade não é superada somente para 15%, enquanto que para o controlador PID, tanto para 10% quanto para 15% o sistema se torna instável.




Figura 4.62 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema servo, 5% de incerteza)




Figura 4.63 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema servo, 10% de incerteza)




Figura 4.64 – Comportamento da variável controlada (coluna de tratamento do CO₂, problema servo, 15% de incerteza)

Para auxiliar na comparação de desempenho entre os controladores RNA e PID, a Tabela 4.21 demonstra os valores de ITAE, ISE e IAE para as simulações realizadas. O símbolo “NaN” corresponde à frase “*Not a number*” gerada pelo programa computacional utilizado quando o limite de dígitos é excedido.

Tabela 4.21 – Valores de ITAE, ISE e IAE para o sistema operando com incertezas nos sensores

ITAE (ppm.s ²)	ISE (ppm ² .s)	IAE (ppm.s)	Controlador	Coluna	Incerteza	Problema
1,24E07	1,68E04	6,00E03	RNA	Etanol	5%	Regulatório
1,90E07	1,07E05	1,65E04	PID			
2,74E08	1,45E07	1,95E05	RNA	CO ₂		
1,15E09	2,95E08	8,20E05	PID			
3,58E07	7,70E05	4,17E04	RNA	Etanol	10%	Regulatório
8,80E07	3,47E05	3,00E04	PID			
6,34E08	3,84E07	2,94E05	RNA	CO ₂		
NaN*	NaN	NaN	PID			
5,12E07	4,45E05	3,26E04	RNA	Etanol	15%	Regulatório
6,84E07	1,18E06	5,25E04	PID			
NaN	NaN	NaN	RNA	CO ₂		
NaN	NaN	NaN	PID			

Continuação da Tabela 4.21

ITAE (ppm.s ²)	ISE (ppm ² .s)	IAE (ppm.s)	Controlador	Coluna	Incerteza	Problema
3,10E07	8,85E04	1,12E04	RNA	Etanol	5%	Servo
2,96E07	2,09E05	2,19E04	PID			
2,79E08	7,85E06	1,42E05	RNA	CO ₂		
4,22E08	3,61E07	2,92E05	PID			
4,94E07	1,98E05	2,08E04	RNA	Etanol	10%	Servo
6,16E07	8,70E05	4,93E04	PID			
4,33E08	2,76E07	2,51E05	RNA	CO ₂		
NaN	NaN	NaN	PID			
5,42E07	4,99E05	3,60E04	RNA	Etanol	15%	Servo
1,61E08	1,82E06	6,80E04	PID			
NaN	NaN	NaN	RNA	CO ₂		
NaN	NaN	NaN	PID			

*NaN = *Not a number*.

Analisando-se os dados apresentados na Tabela 4.21, é possível perceber que o controlador RNA supera o controlador PID para quase todas as configurações estudadas. Mais especificamente, somente para a coluna de recuperação de etanol, problema servo, com 5% de incerteza, os valores de ITAE, ISE e IAE favorecem o controlador PID, ainda que por uma pequena diferença.

CAPÍTULO 5

CONCLUSÕES E SUGESTÕES PARA

TRABALHOS FUTUROS

5.1 CONCLUSÕES

O presente trabalho teve por objetivo a aplicação de uma nova estratégia de controle às colunas de absorção utilizadas no processo de produção de etanol por fermentação, sendo a primeira delas destinada a recuperação do etanol perdido por evaporação, e a segunda responsável pelo tratamento do CO_2 , um co-produto deste processo. Devido a não linearidade geralmente demonstrada por este tipo de equipamento, técnicas convencionais de controle (como por exemplo, o PID) encontram dificuldades em desempenhar suas funções satisfatoriamente. Neste sentido, o controlador *feedforward-feedback* baseado em modelo inverso de redes neurais artificiais possui características que lhe conferem uma maior capacidade de processamento não linear, o que foi extremamente útil na aplicação ao sistema estudado.

Outra dificuldade encontrada pelo sistema de controle diz respeito às incertezas de medição nos sensores utilizados para a tomada de dados do processo. Deste modo, o sistema de controle recebe valores para as variáveis de entrada que podem diferir dos reais. Sendo assim, este trabalho também abordou a influência destas incertezas no desempenho do sistema de controle, analisando-se o problema regulatório e servo para ambas as colunas de absorção.

Depois de implementada a nova estratégia de controle às colunas de absorção estudadas, procederam-se testes nos quais perturbações degrau foram inseridas na composição do gás à entrada da coluna e o desempenho do sistema de controle avaliado para o problema regulatório. Verificou-se através do comportamento da variável controlada (Figura 4.31) que o controlador proposto demonstrou um desempenho superior ao PID para a coluna de recuperação de etanol, pois quando utilizado o controlador RNA o tempo de resposta foi reduzido de 1700s para 150s, aproximadamente. Este melhor desempenho já era esperado, pois aquela coluna demonstrou um comportamento não linear mais acentuado (conforme item 4.2). Já com relação à coluna de absorção para tratamento do CO_2 o melhor desempenho do controlador RNA também pode ser verificado (Figura 4.32), no entanto, devido ao fato desta coluna ter comportamento praticamente linear se esperava que os dois controladores tivessem desempenhos semelhantes. O que se observou foi uma redução do

tempo de resposta de 3400s para 600s, e do *overshoot* de 415ppm para cerca de 340ppm, quando empregado o controlador RNA. A superioridade do controlador RNA também foi comprovada através dos valores obtidos para ITAE, ISE e IAE (conforme Tabela 4.4).

Para o problema servo, novamente o controlador RNA apresentou uma maior capacidade de tratamento de problemas não lineares, pois para a coluna de recuperação de etanol, o controlador proposto, ao contrário do PID (Figura 4.37), não apresentou *overshoot*. Além disso, o tempo de resposta foi reduzido de cerca de 1050s para 150s. Os controladores apresentaram desempenhos com as mesmas características para a coluna de tratamento de CO₂. Neste sentido, o controlador RNA reduziu o tempo de resposta de 750s para 180s quando comparado ao PID, e ainda, não apresentou *overshoot*, ao contrário do PID, 750s (Figura 4.40). Os valores de ITAE, ISE e IAE (conforme Tabela 4.8) suportam estas conclusões.

Visando aproximar, ainda mais, as simulações realizadas da realidade, incertezas de medição foram inseridas nas variáveis de entrada do tipo concentração de etanol/água residual na corrente gasosa, sendo testados três níveis de incerteza: 5, 10 e 15%. Para o problema regulatório, coluna de recuperação de etanol, nenhum dos controladores conseguiu estabilizar a variável controlada no *set point*, no entanto, para todos dos níveis de incerteza testados, o controlador RNA propiciou uma oscilação de menor amplitude para a variável controlada (Figuras 4.53, 4.54 e 4.55). Já para a coluna de tratamento de CO₂, dependendo do nível de incerteza empregado, os controladores encontraram dificuldades em estabilizar o sistema. Neste sentido, para 5% de incerteza o controlador RNA novamente se mostrou superior, propiciando uma menor oscilação da variável controlada, em relação ao PID (Figura 4.56). Para 10% de incerteza a diferença de desempenho entre os controladores foi ainda maior, uma vez que o PID não conseguiu estabilizar o sistema (Figura 4.57). Para 15% de incerteza nenhum controlador conseguiu manter o sistema estável (Figura 4.58).

Analisando-se o problema servo para o sistema operando sob a influência das incertezas de medição, verificou-se que o controlador RNA mais uma vez demonstrou melhor desempenho que o PID, diminuindo a oscilação da variável controlada, para a coluna de recuperação de etanol (Figuras 4.59, 4.60 e 4.61). Com relação a coluna de tratamento de CO₂, a dificuldade em estabilizar o sistema não é superada pelo controlador RNA, somente quando testado um nível de incerteza igual a 15%, já o controlador PID não

consegue desempenhar suas funções com incertezas aos níveis de 10 e 15% (Figuras 4.62, 4.63 e 4.64).

Com base nos vários testes realizados neste trabalho, nos quais foi constatado um desempenho satisfatório do controlador *feedforward-feedback* baseado em modelo inverso de redes neurais, é possível concluir que este representa uma opção atrativa para o controle das colunas de absorção estudadas, principalmente quando o sistema opera sob níveis moderados de incerteza de medição, ou seja, até 10%. Neste sentido, apesar de não conseguir estabilizar a variável controlada no *set point*, o controlador neural proporcionou uma oscilação menor que o controlador PID. Para níveis maiores de incerteza, como por exemplo, 15%, em algumas simulações realizadas os controladores não conseguiram assegurar a estabilidade do sistema, o que demonstra a grande influência das incertezas de medição no desempenho do sistema de controle. Entretanto, mesmo com dificuldades para manter a estabilidade em algumas situações, o controlador RNA demonstrou maior confiabilidade, pois para níveis de incerteza de até 10% de magnitude o controlador obteve êxito nas suas funções, ao contrário do PID, que em alguns testes a este nível de incerteza, não conseguiu garantir a estabilidade do sistema.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Sugere-se que os próximos trabalhos aprofundem o estudo aqui apresentado. Para tanto, pode-se levar em conta os efeitos térmicos sobre a absorção, ou ainda, verificar a influência do tempo morto devido à análise das concentrações de etanol/água residual na corrente gasosa à entrada e à saída da coluna, que compõem o quadro de variáveis de entrada do sistema de controle. Além disso, os testes aqui realizados por meio de simulações podem ser efetuados experimentalmente, para o processo de produção de etanol por fermentação, utilizando-se um sistema de controle composto pelos controladores neural e PID, dispostos em paralelo, prevalecendo o controlador que proporcionar o melhor desempenho para as condições de operação em um dado instante.

REFERÊNCIAS BIBLIOGRÁFICAS

BRAGA, A. de P., LUDERMIR, T. B., CARVALHO, A. C. P. de L. F., *Redes Neurais Artificiais teoria e aplicações*, Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2000.

DEMUTH, H., BEALE, M., *Neural Network Toolbox User's Guide for Use with MATLAB®*. Version 4, Reading: Hagan, M., 2002 Cap. 5: Backpropagation. Disponível em: <http://www.mathworks.com/support/product/NN/>. Acesso em 28/10/2004.

EYNG, E. *Controle Feedforward baseado em redes neurais aplicado a coluna de absorção do processo de produção de etanol*. Campinas: UNICAMP, 2006. Dissertação (Mestrado).

FORESSE, F. D., HAGAN, M. T., *Gauss-Newton Approximation to Bayesian Learning*. In Proceedings of the 1997 International Joint Conference on Neural Networks, 1997, URL: <http://elec-engr.okstate.edu/mhagan/>. Acesso em 06/11/2004.

KERNANI, B. G., SCHIFFMAN, S. S., NAGLE, H. T., *Performance of the Levenberg-Marquardt neural network training method in electronic nose applications*. Sensors and Actuators B, Elsevier B. V., 2005.

LUYBEN, W. L., *Process Modeling, Simulation and Control for Chemical Engineers*. McGraw – Hill Book Company, 1990.

MAIA, M. L. O. *Controle preditivo de Colunas de Absorção*. Campinas: UNICAMP, 1994. Dissertação (Mestrado)

MCCULLOCH, W., PITTS, W. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Math. Bio., n.5, p. 115-133, 1943.

MELEIRO L. A. da C., COSTA, A. C. da, MACIEL, R. Filho, Non-linear multivariable control of an alcoholic fermentation process using functional link networks, *Brazilian Archives of Biology and Technology*. 48, 2005, no.spe, 7-18.

NAJIM, K., RUIZ, V. *Long-range predictive control of an absorption packed column*. Appl. Math. Modelling. v. 19, p. 39-45, 1995.

NUNES, G. C., KINCAL, S., CRISALLE, O. *A polynomial perspective on the stability of multivariable predictive controllers*. Computers and Chemical Engineering. v. 27, p. 1097-1111, 2003.

OGUNNAYKE, B. A., RAY, W. H., *Process Dynamics, Modeling, and Control*. Oxford University Press, 1994.

PACIANOTTO, T. A., *Aplicação de Redes Neurais para o ajuste operacional do período final de sopro de um processo de aciaria a oxigênio*. Campinas: UNICAMP, 2003. Dissertação (Mestrado).

PALÚ, F. *Controle preditivo de colunas de absorção com o método de controle por matriz dinâmica*. Campinas: UNICAMP, 2001. Tese (Doutorado)

PARTHASARATHY, S., GOWAN H., INDHAR, P. *Prediction of Flooding in an Absorption Column using Neural Networks*. International Conference on Control Applications, 1999.

RÓG, E., WILK, M. *Simulation of an absorption column performance using feed-forward neural networks in nitric acid production*. Computers Chemical Engineering. v. 22, p. 909-912, 1998.

RUMMELHART, D., MCCLELLAND, J. *Parallel Distributed Processing*. MIT Press, Cambridge, 1986.

SALOMÃO, A., ONAGA, M., *Etanol: o mundo quer. O Brasil tem*. Revista EXAME, Editora Abril, edição 870, ano 40, nº12, p. 18 – 24, junho, 2006.

SEBORG, D. E., EDGAR, T. F., MELLICHAMP, D. A., *Process Dynamics and Control*. Hamilton Printing Company, 1989.

SHERWOOD, T. K., PIGFORD, R. L., WILKE, C. R. *Mass Transfer*. McGraw-Hill, 1975.

SHREVE, R. N., BRINK JR., J. A., *Indústrias de Processos Químicos*. 4ª edição, Editora Guanabara Koogan, 1997.

SILVA, J. E. L. e, *Simulação e Controle Preditivo Linear (com Modelo de Convolução) e Não-Linear (Com Modelo baseado em Redes Neurais Artificiais) de Colunas Recheadas de Absorção com Reação Química*. Campinas: UNICAMP, 1997. Dissertação (Mestrado).

SMITH, C. A., CORRIPIO, A. *Princípios e Prática do Controle Automático de Processos*. 3ª edição LTC, 2008.

STEPHANOPOULOS, G., *Chemical Process Control An Introduction to Theory and Practice*. PTR Prentice Hall, 1984.

TREYBAL, R. E., *Mass-Transfer Operations*. McGraw – Hill Book Company, 1981.

ZAPAROLLI, D., Queda de preços do biodiesel e do álcool gera incertezas, mas perspectivas no longo prazo ainda são positivas, *Química e derivados*, Editora QD Ltda p.15 – 18, fevereiro, 2008.

ANEXOS

ANEXO 01 - PROGRAMA COMPUTACIONAL EM MATLAB®
MODELO_COLUNA_DE_ABSORCAO_ETANOL.M

global N L X Y M MX G L0 X0 MM LW AP HV C DT ELN1 ELN EXN1 EXN EYN1 EYN DerM DerMX
Y_defasado Y_atual

%#####

%Etapa 1 - Entrada de dados

N=9;	% N = Numero de pratos
G=61.9;	% G = Vazao de gas
X0=0.0001;	% X0 = Fração molar do componente A no liquido de entrada
YN=0.01;	% YN = Fração molar do componente A no gas de entrada
Y1=0.0002;	% Y1 = Fração molar do componente A no gas de saida
MM=1.0682;	% MM = Constante de equilibrio
LW=8.3;	% LW = Comprimento do vertedouro
C=0.14322;	% C = Constante
HV=8;	% HV = Altura do vertedouro
AP=210;	% AP = Area do prato
DT=0.05;	% DT = Passo de integraçao
TEMPOFINAL=400;	% TEMPOFINAL = Ultimo valor do tempo desejado
L0=98.248;	% L0 = Vazao de solvente inicial (vazao otima)
Perturb_Y=1;	% Determina se ha perturbação em Y(N+1)/ 0-nao 1-sim
ValorP_Y=[10];	% ValorP_Y = Valor percentual da perturbação em Y(N+1)
tperturb_Y=0;	% Instante no qual ha a perturbação em Y(N+1)
int_perturb_Y=110;	% Intervalo entre cada perturbação em Y(N+1)
Perturb_X=0;	% Determina se ha perturbação em X0/ 0-nao 1-sim
ValorP_X=[30];	% ValorP_Y = Valor percentual da perturbação em X0
tperturb_X=0;	% Instante no qual ha a perturbação em X0
int_perturb_X=110;	% Intervalo entre cada perturbação em X0
Perturb_L=0;	% Determina se ha perturbação em L0/ 0-nao 1-sim
ValorP_L=[-10];	% ValorP_L = Valor percentual da perturbação em L0
tperturb_L=0;	% Instante no qual ha a perturbação em L0
int_perturb_L=110;	% Intervalo entre cada perturbação em L0
Y1sp=200;	% Valor desejado para Y1 (set point)(*1e6)
erro_percentual_max=5;	% Porcentagem maxima de erro toleravel (valor absoluto)
f_PI=0;	% Valor inicial da fração de L0 proveniente do controlador PI
kc=22000;	% Parametro kc do controlador PI
tal_i=10400;	% Parametro tal_i do controlador PI
tal_d=60;	% Parametro tal_d do controlador PID
Control_cont=1;	% Determina se o sistema sera controlado (1) ou nao (0)
NA=15;	% Numero de instantes de amostragem anteriores a k

```

#####
% Etapa 02 – Dados para normalização das variáveis
minp=[197.9679; 197.9679; 197.9679; 96.1991; 0.009];
maxp=[201.9447; 201.9447; 201.9447; 100.1769; 0.011];
minL0 = 96.1991;
maxL0 = 100.1769;

#####
% Etapa 03 – Calculo dos valores iniciais de M(I), X(I), MX(I) e Y(I)
Y(1)=Y1;
X(1)=Y(1)/MM;
for i=2:N
    Y(i)=4.12791E-5 + 1.5872*X(i-1);
    X(i)=Y(i)/MM;
end
Y(N+1)=4.12791E-5 + 1.5872*X(N);
for i=1:N
    L(i)=L0; % L(i) = Vazao do liquido em cada prato
    RO=0.01713*X(i) + 0.05551*(1-X(i));
    % RO = Massa especifica molar media da mistura
    M(i)=AP*RO*(((L(i)/(RO*LW))^0.666667)*C+HV);
end
for i=1:N %Valores iniciais de MX
    MX(i)=M(i)*X(i);
end

#####

% Etapa 04 – Dados pré-laço while
TEMPO=0; % Tempo inicial
t_print=0; % Valor inicial do tempo para impressao em arquivo ascii
TA = 0; % Valor inicial do tempo de amostragem
ISE=0; % Valor inicial da integral do quadrado do erro
ITAE=0; % Valor inicial da integral do erro ponderado pelo tempo
IAE=0; % Valor inicial da integral o erro absoluto
k=1; % Contador do vetor de dados para arquivo em ascii
Y_PRINT(k)= Y(1)*1e6; % Impressao de Y1 inicial para arquivo em ascii (valor inicial)
L0_PRINT(k)=L0; % Impressao de L0 inicial para arquivo em ascii
T_PRINT(k)=TEMPO; % Impressao de TEMPO inicial para arquivo em ascii (valor inicial)

```

```

L0_atual = L0; % Valor inicial da variavel de entrada da rede L0|k
SP(k)=200; % Set point para arquivo em ascii
k=k+1; % Atualizacao do contador do vetor de dados
kk=1; % Valor inicial do contador do vetor dos dados filtrados
TA_print(1)=1; % Valor inicial do Tempo de Amostragem para impressao
pt_Y=1; % Contador do vetor perturbacao ValorP_Y
pt_X=1; % Contador do vetor perturbacao ValorP_X
pt_L=1; % Contador do vetor perturbacao ValorP_L
Controle=0; % Inicialmente o sistema esta desativado, somente e ativado quando TA e
atingido

erro=0; % Valor Inicial do erro
erro_antigo=0; % Valor Inicial do erro em um instante anterior
int_e =0; % Valor inicial da Integral do erro
der_e=0; % Valor inicial da Derivada do erro
L0_PID =L0; % Valor inicial da vazao de solvente proveniente do controlador PID
PID_cont = 0; % Contador do controlador PID
Y_atual=Y(1)*1e6; % Valor inicial da variavel de entrada da rede Y1|k
YN_atual=Y(N+1); % Valor inicial da variavel de entrada da rede Y(N+1)|k
for i=1:NA
    Y_defasado(i)=Y_atual;
    YN_defasado(i)=YN_atual;
end

while (TEMPO <= TEMPOFINAL)
    % Inicio do laço While

    %#####
    % Etapa 05 – Calculo dos valores de Y(i)
    for i=1:N
        Y(i)=MM*X(i);
    end
    if TA >= 3
        for i=NA:-1:2
            Y_defasado(i)=Y_defasado(i-1);
            YN_defasado(i)=YN_defasado(i-1);
        end
        Y_defasado(1) = Y_atual;
        YN_defasado(1) = YN_atual;
        Y_atual = Y(1)* 1e6; L0_atual=L0; YN_atual=Y(N+1);
    end
end

```



```

                                % Atualização das demais variáveis de entrada

    if Control_cont == 1
        Controle = 1;
    End

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 06 – Atualização dos dados para o controlador PID
if R == 0                                % Caso R=0, então F=0
    Y1_PID = Y(1);
end
erro_antigo= erro;
erro= Y1_PID-(Y1sp*1e-6);
erro_percentual = ((erro)/(Y1sp*1e-6))*100;
                                % Porcentagem de erro na variável controlada

int_e= int_e + erro*TA;
der_e = (erro-erro_antigo)/TA;
var_e = (erro-erro_antigo);
TA=0;
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 07 – Cálculo dos valores de L(i)
for i=1:N
    RO=0.01713*X(i) + 0.05551*(1-X(i));
    L(i)=RO*LW*(((M(i)/(AP*RO))-HV)/C)^1.5);
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 08 – Impressão dos Resultados
if t_print >= 1                                % Dados para impressão em arquivo ascii
    Y_PRINT(k)= Y(1)*1e6; T_PRINT(k)=TEMPO; SP(k)=200; L0_PRINT(k)=L0;
    k=k+1;
    t_print=0;
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 09 – Controle RNA
if Controle == 1
    Z=[Y_atual; Y_defasado(1); Y1sp; L0_atual; YN_atual];

```

```

                                % Normalização das variaveis

for i= 1:5
    Zn(i,1)= 2*(Z(i,1)-minp(i,1))/(maxp(i,1)-minp(i,1)) - 1;
end

                                % Rede_Coluna_de_Absorcao_Simulacao

SR= sim(net,Zn);                %Simulação da rede com os novos dados de entrada

                                % Desnormalização das variaveis
                                % Definição da vazao de solvente proveniente da RNA
L0_RNA = (((SR+1)*(maxL0-minL0))/2)+minL0;

%#####

% Etapa 10 – Controlador PID
if abs(erro_percentual) >= erro_percentual_max
    f_PI=1;                      % Ateracao da fração de L0 proveniente do controlador PID
end

                                % Definição da vazao de solvente proveniente do controlador PID
L0_PI= L0_PID + kc*erro + (kc/tal_i)*int_e + (kc*tal_d)*der_e;

%#####

% Etapa 11 – Definição da ação de controle
L0 = (L0_RNA*(1-f_PID))+(L0_PID*f_PID);
Controle=0;
end

%#####

% Etapa 12 – Euler
Euler;

%#####

% Etapa 13 – Inserção das Perturbações em Y(N+1) e/ou X0 e/ou L0
if Perturb_Y == 1
    if TEMPO >= tperturb_Y
        Y(N+1)=Y(N+1)*(1+(ValorP_Y(pt_Y)/100));
        tperturb_Y= tperturb_Y + int_perturb_Y;
        pt_Y=pt_Y + 1;
        if pt_Y == 2

```

```

        tperturb_Y=TEMPOFINAL+10*DT;
    end
end
end
if Perturb_X == 1
    if TEMPO >= tperturb_X
        X0 = X0*(1+(ValorP_X(pt_X)/100));
        tperturb_X= tperturb_X + int_perturb_X;
        pt_X=pt_X + 1;
        if pt_X == 2
            tperturb_X=TEMPOFINAL+10*DT;
        end
    end
end
end
if Perturb_L == 1
    if TEMPO >= tperturb_L
        L0=L0*(1+(ValorP_L(pt_L)/100));
        tperturb_L= tperturb_L + int_perturb_L;
        pt_L=pt_L + 1;
        if pt_L == 2
            tperturb_L=TEMPOFINAL+10*DT;
        end
    end
end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 14 – Impressão do erro
erro_print= Y(1)-(Y1sp*1e-6);
erro_percentual_print = ((erro_print)/(Y1sp*1e-6))*100;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 15 – Cálculo dos parâmetros de comparação
ISE=ISE + (erro_print^2);
ITAE=ITAE + (erro_print)*DT;
IAE=IAE + (erro_print);

TEMPO = TEMPO + DT
t_print = t_print + DT;
TA = TA + DT;

```

```

end                                     % Fim do laço WHILE

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Etapa 16 – Impressão dos resultados
T_PRINT= T_PRINT'; Y_PRINT= Y_PRINT'; SP = SP'; L0_PRINT = L0_PRINT';
Y_atualprint=Y_atualprint' ; YN_atualprint=YN_atualprint' ; TA_print = TA_print' ;
W=[T_PRINT Y_PRINT SP L0_PRINT];
WW=[TA_print Y_atualprint YN_atualprint];
save SaidaW.dat W /ascii;             % Impressao em arquivo ascii
save SaidaWW.dat WW /ascii;

```

ANEXO 02 – PROGRAMA COMPUTACIONAL EM MATLAB®
REDE_COLUNA_DE_ABSORCAO_TREINAMENTO_ETANOL.M

```

#####
% Etapa 01 – Dados para treinamento da rede
DTR=load('BCD_Treinamento5.dat');
entrada=DTR(:,1:5);          %Dados de entrada da rede
saida=DTR(:,6);              %Dados de saida da rede
entrada = entrada';
saida = saida';

#####
% Etapa 02 – Normalização das variaveis
[entradan, minentrada, maxentrada, saidan, minsaida, maxsaida] = premnmx(entrada, saida);

#####
% Etapa 03 – Arquitetura da rede
net.numinputs = size(entrada,5);
                                %Numero de variaveis de entrada
net.numLayers = 2;              %Numero de camadas, sem considerar a camada de entrada
net = newff(minmax(entradan),[9,1],{'tansig','purelin'},'trainbr');

#####
% Etapa 04 – Treinamento da rede
net.trainParam.epochs = 5000;
                                %Numero de passos
net.trainParam.show = 25;       %Atualiza no grafico o numero de passos
net.trainParam.goal = 1e-6;     %Convergencia desejada
net.initFcn = 'initlay';        %Funcao que inicia os pesos e bias
net.performFcn = 'sse';         %Funcao objetivo a ser minizada
net.trainParam.min_grad= 1e-100;
                                %Minimo gradiente
net.trainParam.mu_max = 1e+100;
                                %Max MU
net = init(net);                %Inicialização da rede
[net,tr] = train(net, entradan, saidan);
                                %Realiza o treinamento (determina pesos)
#####
% Etapa 05 – Simulação utilizando-se a rede
% DVR = Dados para Validação da Rede
DVR= load('BCD_Validacao.dat');
                                %Leitura dos dados de teste

```

```

in= DVR(:,1:5);          %Dados de entrada
out= DVR(:,6);           %Dados de saida
in= in';
out= out';
%#####
% Etapa 06 – Normalização das variaveis
minp=[197.9679; 197.9679; 197.9679; 96.1991; 0.009];
maxp=[201.9447; 201.9447; 201.9447; 100.1769; 0.011];
minL0 = 96.1991;
maxL0 = 100.1769;
[liin,colin]=size(in);
[liout,colout]=size(out);
for j=1:colin
    for i= 1:liin
        inn(i,j)= 2*(in(i,j)-minp(i,1))/(maxp(i,1)-minp(i,1)) - 1;
    end
end
for j=1:colout
    for i= 1:liout
        outn(i,j)= 2*(out(i,j)-minL0)/(maxL0-minL0) - 1;
    end
end
% SR= Simulacao da Rede
% DSR= Dados provenientes da Simulação da Rede
SR= sim(net,inn);          %Simulação da rede com os novos dados de entrada
DSR = (((SR+1)*(maxL0-minL0))/2)+minL0;%Desnormalização
figure(1);
plot(out,':')              % plota a variavel de saida.
hold on
plot(DSR,'r');             % plota a variavel de saida fornecida pela rede.
xlabel('eixo x')
ylabel('eixo y')
hold off
figure(2);
[m,b,r]= postreg(out,DSR);
for i=1:488
    erro_sse(i) = out(1,i)-DSR(1,i);
end
sse_validacao=sse(erro_sse)

```


ANEXO 03 – ARQUIVOS .M SECUNDÁRIOS EM MATLAB®

% Arquivo Derivadas.m

% Calculo das derivadas para a utilização em Euler

global ELN1 ELN EXN1 EXN EYN1 EYN G DerM DerMX

DerM(i)= ELN1 - ELN;

DerMX(i)= (ELN1*EXN1) - (ELN*EXN) + (G*(EYN1 - EYN));

% Arquivo Definicao.m

%Definição dos valores de X e Y utilizados em Runge_Kutta

global N L0 X0 ELN1 ELN EXN1 EXN EYN1 EYN X Y L

if i==1

ELN1=L0; ELN=L(i); EXN1=X0;

EXN=X(i); EYN1=Y(i+1); EYN=Y(i);

else

ELN1=L(i-1); ELN=L(i); EXN1=X(i-1);

EXN=X(i); EYN1=Y(i+1); EYN=Y(i);

end

% Arquivo Euler.m

% Aplicação do metodo de Euler

global N L0 X0 ELN1 ELN EXN1 EXN EYN1 EYN X Y L DerM DerMX G MX M

for i=1:N

Definicao; %Define os valores de ELN1 ELN EXN1 EXN EYN1 EYN

Derivadas; %Calcula as derivadas DerM e DerMX

M(i)=M(i) + (DerM(i)*DT);

MX(i)=MX(i) + (DerMX(i)*DT);

X(i)=MX(i)/M(i);

End

**ANEXO 04 – ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® - MODELO_COLUNA_DE_ABSORCAO_CO2.M**

% Etapa 01: Entrada de dados

%#####

```
N=7; % N = Numero de pratos
G=60.3; % G = Vazao de gas
X0=0.001; % X0 = Fração molar do componente A no liquido de entrada
YN=0.02; % YN = Fração molar do componente A no gas de entrada
Y1=0.003; % Y1 = Fração molar do componente A no gas de saída
X1=0.58662366286968; % X1 = Obtido atraves de interpolação spline para Y1
%MM=1.0682; % MM = Constante de equilibrio
LW=8.3; % LW = Comprimento do vertedouro
C=0.14322; % C = Constante
HV=8; % HV = Altura do vertedouro
AP=210; % AP = Area do prato
DT=0.05; % DT = Passo de integração
TEMPOFINAL=3700; % TEMPOFINAL = Ultimo valor do tempo desejado
T_impressao=59.95; % Tempo de impressao nos arquivos ascii.
L0=1.36354312481517; % L0 = Vazao de solvente inicial (vazao otima)
Perturb_Y=1; % Determina se ha perturbação em Y(N+1)/ 0-nao 1-sim
PY=2.7;
ValorP_Y=[PY]; % ValorP_Y = Valor percentual da perturbação em Y(N+1)
tperturb_Y=0; % Instante no qual ha a perturbação em Y(N+1)
int_perturb_Y=110; % Intervalo entre cada perturbação em Y(N+1)
Perturb_X=0; % Determina se ha perturbação em X0/ 0-nao 1-sim
ValorP_X=[30]; % ValorP_Y = Valor percentual da perturbação em X0
tperturb_X=0; % Instante no qual ha a perturbação em X0
int_perturb_X=110; % Intervalo entre cada perturbação em X0
Perturb_L=0; % Determina se ha perturbação em L0/ 0-nao 1-sim
ValorP_L=[-3]; % ValorP_L = Valor percentual da perturbação em L0
tperturb_L=0; % Instante no qual ha a perturbação em L0
int_perturb_L=110; % Intervalo entre cada perturbação em L0
Y1sp=300; % Valor desejado para Y1 (set point)(*1e6)
erro_percentual_max=5; % Porcentagem maxima de erro toleravel (valor absoluto)
f_PID=1; % Valor inicial da fração de L0 proveniente do controlador PID
kc=50; % Parametro kc do controlador PID
tal_i=100; % Parametro tal_i do controlador PID
tal_d=300; % Parametro tal_d do controlador PID
kc=850; % Parametro kc do controlador PID
```

```

tal_i=35;                % Parametro tal_i do controlador PID
tal_d=10;                % Parametro tal_d do controlador PID
Control_cont=1;          % Determina se o sistema sera controlado (1) ou nao (0)
NY=2;                   % Numero de instantes de amostragem anteriores a k para a entrada da rede

% #####

% Etapa 02: Normalização das variáveis

minp=[153.873930; 153.873930;      153.873930;      1.285524; 0.019000];
maxp=[525.976010; 525.976010;      525.976010;      1.445973; 0.021000];
minL0 = 1.285524;
maxL0 = 1.445973;
% #####

% Etapa 03: Calculo dos valores iniciais de M(I), X(I), MX(I) e Y(I)
VI=xlsread('Valores_iniciais.xls','Plan1');
for i=1:N
    X(i)=VI(i,1);
    Y(i)=VI(i,2);
    RO(i)=VI(i,3);
    L(i)=VI(i,4);
    M(i)=VI(i,5);
    MX(i)=VI(i,6);
end
Y(N+1)=YN;

```


**ANEXO 05– ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® – REDE_TREINAMENTO_COLUNA_DE_ABSORCAO_CO2.M**

```

%DTR = Dados para Treinamento da Rede
DTR=load('BCD_Treinamento_CO2_ultimo.dat');
entrada=DTR(:,1:5);          %Dados de entrada da rede
saida=DTR(:,6);              %Dados de saida da rede
entrada = entrada';
saida = saida';

% Normalização das variaveis
[entradan, minentrada, maxentrada, saidan, minsaida, maxsaida] = premnmx(entrada, saida);
%Arquitetura da rede
net.numinputs = size(entrada,5);    %Numero de variaveis de entrada
net.numLayers = 2;                  %Numero de camadas, sem considerar a camada de entrada
net = newff(minmax(entradan),[10,1],{'tansig','purelin'},'trainbr');
%Treinamento da rede
net.trainParam.epochs = 5000;       %Numero de passos
net.trainParam.show = 25;           %Atualiza no grafico o numero de passos
net.trainParam.goal = 1e-6;         %Convergencia desejada
net.initFcn = 'initlay';            %Funcao que inicia os pesos e bias
net.performFcn = 'sse';             %Funcao objetivo a ser minizada
net.trainParam.min_grad= 1e-100;    %Minimo gradiente
net.trainParam.mu_max = 1e+100;     %Max MU
net = init(net);                    %Inicialização da rede

[net,tr] = train(net, entradan, saidan); %Realiza o treinamento (determina pesos)

%Simulação utilizando-se a rede
% DVR = Dados para Validação da Rede

DVR= load('BCD_Validacao_CO2.dat'); %Leitura dos dados de teste
in= DVR(:,1:5);                    %Dados de entrada
out= DVR(:,6);                     %Dados de saida
in= in';
out= out';

% Normalização das variaveis
minp=[153.873930; 153.873930;      153.873930;      1.285524; 0.019000];
maxp=[525.976010; 525.976010;      525.976010;      1.445973; 0.021000];
minL0 = 1.285524;
maxL0 = 1.445973;

```


**ANEXO 06 – ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® – MODELO_COLUNA_DE_ABSORCAO_SERVO_ETANOL.M**

```

% Etapa 01: Entrada de dados
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
N=9;                % N = Numero de pratos
G=61.9;            % G = Vazao de gas
X0=0.0001;         % X0 = Fração molar do componente A no liquido de entrada
YN=0.01;           % YN = Fração molar do componente A no gas de entrada
Y1=0.0002;         % Y1 = Fração molar do componente A no gas de saída
MM=1.0682;         % MM = Constante de equilibrio
LW=8.3;            % LW = Comprimento do vertedouro
C=0.14322;         % C = Constante
HV=8;              % HV = Altura do vertedouro
AP=210;            % AP = Area do prato
DT=0.05;           % DT = Passo de integração
TEMPOFINAL=3700;   % TEMPOFINAL = Ultimo valor do tempo desejado
T_impressao=59.95; % Tempo de impressao nos arquivos ascii.
L0=98.248;         % L0 = Vazao de solvente inicial (vazao otima)
Perturb_Y=0;        % Determina se ha perturbacao em Y(N+1)/ 0-nao 1-sim
PY=4.3;
ValorP_Y=[PY];      % ValorP_Y = Valor percentual da perturbacao em Y(N+1)
tperturb_Y=0;       % Instante no qual ha a perturbacao em Y(N+1)
int_perturb_Y=110;   % Intervalo entre cada perturbacao em Y(N+1)
Perturb_Y1sp=1;      % Determina se ha perturbacao em Y1sp/ 0-nao 1-sim
PY1sp=13.7;
ValorP_Y1sp=[PY1sp]; % ValorP_Y1sp = Valor percentual da perturbacao em Y1sp
tperturb_Y1sp=0;     % Instante no qual ha a perturbacao em Y1sp
int_perturb_Y1sp=110; % Intervalo entre cada perturbacao em Y1sp
Perturb_X=0;         % Determina se ha perturbacao em X0/ 0-nao 1-sim
ValorP_X=[20];       % ValorP_Y = Valor percentual da perturbacao em X0
tperturb_X=0;        % Instante no qual ha a perturbacao em X0
int_perturb_X=110;   % Intervalo entre cada perturbacao em X0
Perturb_L=0;         % Determina se ha perturbacao em L0/ 0-nao 1-sim
ValorP_L=[20];       % ValorP_L = Valor percentual da perturbacao em L0
tperturb_L=0;        % Instante no qual ha a perturbacao em L0
int_perturb_L=110;   % Intervalo entre cada perturbacao em L0
Y1sp=200;            % Valor desejado para Y1 (set point)(*1e6)
erro_percentual_max=5; % Porcentagem maxima de erro toleravel (valor absoluto)
f_PID=1;             % Valor inicial da fração de L0 proveniente do controlador PID
kc=70000;            % Parametro kc do controlador PID para incerteza de 15%
tal_i=100;           % Parametro tal_i do controlador PID para incerteza de 15%

```

```

tal_d=10;          % Parametro tal_d do controlador PID para incerteza de 15%
Control_cont=1;    % Determina se o sistema sera controlado (1) ou nao (0)
NA=15;            % Numero de instantes de amostragem anteriores a k
NY=1;             % Numero de instantes de amostragem anteriores a k para a entrada da rede

% Etapa 02: Normalização das variáveis
%#####

minp=[147.025500; 147.025500;      147.025500;      92.017256];
maxp=[254.069060; 254.069060;      254.069060;      110.135820];
minL0 = 92.017256;
maxL0 = 110.135820;

% Etapa 13: Inserção das perturbações
%#####

if Perturb_Y1sp == 1
    if TEMPO >= tperturb_Y1sp
        Y1sp=Y1sp*(1+(ValorP_Y1sp(pt_Y1sp)/100));
        tperturb_Y1sp= tperturb_Y1sp + int_perturb_Y1sp;
        pt_Y1sp=pt_Y1sp + 1;
        if pt_Y1sp == 2
            tperturb_Y1sp=TEMPOFINAL+10*DT;
        end
    end
end
end

```


**ANEXO 07– ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® -
REDE_TREINAMENTO_COLUNA_DE_ABSORCAO_SERVO_ETANOL.M**

```

%DTR = Dados para Treinamento da Rede

DTR=load('BCD_Treinamento_Etanol_servo.dat');

entrada=DTR(:,1:4);          %Dados de entrada da rede

saida=DTR(:,5);             %Dados de saida da rede

entrada = entrada';

saida = saida';

% Normalização das variaveis

[entradan, minentrada, maxentrada, saidan, minsaida, maxsaida] = premnmx(entrada, saida);

%Arquitetura da rede

net.numinputs = size(entrada,4);      %Numero de variaveis de entrada

net.numLayers = 2;                  %Numero de camadas, sem considerar a camada de
entrada

net = newff(minmax(entradan),[6,1],{'tansig','purelin'},'trainbr');

%Treinamento da rede

net.trainParam.epochs = 5000;        %Numero de passos

net.trainParam.show = 25;           %Atualiza no grafico o numero de passos

net.trainParam.goal = 1e-6;         %Convergencia desejada

net.initFcn = 'initlay';            %Funcao que inicia os pesos e bias

net.performFcn = 'sse';              %Funcao objetivo a ser minizada

net.trainParam.min_grad= 1e-100;    %Minimo gradiente

net.trainParam.mu_max = 1e+100;     %Max MU

net = init(net);                    %Inicialização da rede

[net,tr] = train(net, entradan, saidan); %Realiza o treinamento (determina pesos)

%Simulação utilizando-se a rede

% DVR = Dados para Validação da Rede

DVR= load('BCD_Validacao_Etanol_servo.dat');    %Leitura dos dados de teste

in= DVR(:,1:4);          %Dados de entrada

out= DVR(:,5);           %Dados de saida

in= in';

```

```
out= out';  
  
% Normalização das variaveis  
  
minp=[147.025500; 147.025500;      147.025500;      92.017256];  
maxp=[254.069060; 254.069060;      254.069060;      110.135820];  
  
minL0 = 92.017256;  
  
maxL0 = 110.135820;
```


**ANEXO 08 – ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® - MODELO_COLUNA_DE_ABSORCAO_SERVO_CO2.M**

```

% Etapa 01: Entrada de dados

% #####

N=7;                % N = Numero de pratos

G=60.3;            % G = Vazao de gas

X0=0.0001;         % X0 = Fração molar do componente A no liquido de entrada

YN=0.02;           % YN = Fração molar do componente A no gas de entrada

Y1=0.0003;         % Y1 = Fração molar do componente A no gas de saída

X1=0.58662366286968; % X1 = Obtido atraves de interpolação spline para Y1

%MM=1.0682;        % MM = Constante de equilibrio

LW=8.3;            % LW = Comprimento do vertedouro

C=0.14322;         % C = Constante

HV=8;              % HV = Altura do vertedouro

AP=210;            % AP = Area do prato

DT=0.05;           % DT = Passo de integração

TEMPOFINAL=3700;   % TEMPOFINAL = Ultimo valor do tempo desejado

T_impressao=59.95; % Tempo de impressao nos arquivos ascii.

L0=1.36354312481517; % L0 = Vazao de solvente inicial (vazao otima)

Perturb_Y=0;        % Determina se ha perturbação em Y(N+1)/ 0-nao 1-sim

PY=4.3;

ValorP_Y=[PY];      % ValorP_Y = Valor percentual da perturbação em Y(N+1)

tperturb_Y=0;       % Instante no qual ha a perturbação em Y(N+1)

int_perturb_Y=110;   % Intervalo entre cada perturbação em Y(N+1)

Perturb_Y1sp=1;      % Determina se ha perturbação em Y1sp/ 0-nao 1-sim

PY1sp=12.8;

ValorP_Y1sp=[PY1sp]; % ValorP_Y1sp = Valor percentual da perturbação em Y1sp

tperturb_Y1sp=0;     % Instante no qual ha a perturbação em Y1sp

int_perturb_Y1sp=110; % Intervalo entre cada perturbação em Y1sp

Perturb_X=0;         % Determina se ha perturbação em X0/ 0-nao 1-sim

ValorP_X=[30];       % ValorP_Y = Valor percentual da perturbação em X0

```

```

tperturb_X=0;      % Instante no qual ha a perturbação em X0
int_perturb_X=110;      % Intervalo entre cada perturbação em X0
Perturb_L=0;      % Determina se ha perturbação em L0/ 0-nao 1-sim
ValorP_L=[2];      % ValorP_L = Valor percentual da perturbação em L0
tperturb_L=0;      % Instante no qual ha a perturbação em L0
int_perturb_L=110;      % Intervalo entre cada perturbação em L0
Y1sp=300;      % Valor desejado para Y1 (set point)(*1e6)
erro_percentual_max=5;      % Porcentagem maxima de erro toleravel (valor absoluto)
f_PID=1;      % Valor inicial da fração de L0 proveniente do controlador PID
kc=275;      % Parametro kc do controlador PID
tal_i=200;      % Parametro tal_i do controlador PID
tal_d=50;      % Parametro tal_d do controlador PID
Control_cont=1;      % Determina se o sistema sera controlado (1) ou nao (0)
NY=1;      % Numero de instantes de amostragem anteriores a k para a entrada da rede

```

```

% Etapa 02: Normalização das variáveis

```

```

minp=[201.054310; 201.054310;      201.054310;      1.328350];
maxp=[435.176340; 435.176340;      435.176340;      1.398736];
minL0 = 1.328350;
maxL0 = 1.398736;

```

```

% Etapa 09: Controle RNA

```

```

%#####

```

```

if Controle == 1

```

```

Z=[Y_atual; Y_entrada_defasada(1); Y1sp; L0_atual];

```

```

% Normalização das variaveis

```

```

for i= 1:4

```

```

    Zn(i,1)= 2*(Z(i,1)-minp(i,1))/(maxp(i,1)-minp(i,1)) - 1;

```

```

end

```

```

% Rede_Coluna_de_Absorcao_Simulacao

SR= sim(net,Zn);          %Simulação da rede com os novos dados de entrada

% Desnormalização das variaveis /

% Definição da vazao de solvente proveniente da RNA

L0_RNA = (((SR+1)*(maxL0-minL0))/2)+minL0;

% Etapa 13: Inserção das perturbações

%#####

if Perturb_Y1sp == 1

    if TEMPO >= tperturb_Y1sp

        Y1sp=Y1sp*(1+(ValorP_Y1sp(pt_Y1sp)/100));

        tperturb_Y1sp= tperturb_Y1sp + int_perturb_Y1sp;

        pt_Y1sp=pt_Y1sp + 1;

        if pt_Y1sp == 2

            tperturb_Y1sp=TEMPOFINAL+10*DT;

        end

    end

end

end

```

**ANEXO 09– ADAPTAÇÕES DO PROGRAMA COMPUTACIONAL EM
MATLAB® –
REDE_TREINAMENTO_COLUNA_DE_ABSORCAO_SERVO_CO2.M**

```

%DTR = Dados para Treinamento da Rede

DTR=load('BCD_Treinamento_CO2_servo.dat');

entrada=DTR(:,1:4);          %Dados de entrada da rede

saida=DTR(:,5);             %Dados de saida da rede

entrada = entrada';

saida = saida';

% Normalização das variaveis

[entradan, minentrada, maxentrada, saidan, minsaida, maxsaida] = premnmx(entrada, saida);

%Arquitetura da rede

net.numinputs = size(entrada,4);      %Numero de variaveis de entrada

net.numLayers = 2;                  %Numero de camadas, sem considerar a camada de
entrada

net = newff(minmax(entradan),[8,1],{'tansig','purelin'},'trainbr');

%Treinamento da rede

net.trainParam.epochs = 5000;        %Numero de passos

net.trainParam.show = 25;           %Atualiza no grafico o numero de passos

net.trainParam.goal = 1e-6;         %Convergencia desejada

net.initFcn = 'initlay';            %Funcao que inicia os pesos e bias

net.performFcn = 'sse';              %Funcao objetivo a ser minizada

net.trainParam.min_grad= 1e-100;    %Minimo gradiente

net.trainParam.mu_max = 1e+100;     %Max MU

net = init(net);                    %Inicialização da rede

[net,tr] = train(net, entradan, saidan); %Realiza o treinamento (determina pesos)

%Simulação utilizando-se a rede

% DVR = Dados para Validação da Rede

DVR= load('BCD_Validacao_CO2_servo.dat'); %Leitura dos dados de teste

in= DVR(:,1:4);                    %Dados de entrada

out= DVR(:,5);                     %Dados de saida

in= in';

```

```
out= out';  
  
% Normalização das variaveis  
  
minp=[201.054310; 201.054310;      201.054310;      1.328350];  
maxp=[435.176340; 435.176340;      435.176340;      1.398736];  
  
minL0 = 1.328350;  
maxL0 = 1.398736;
```