



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA QUÍMICA

AUTORA: DÉBORA ZENAIDE GORRI MAZZALI

**ANÁLISE DOS EFEITOS DOS PARÂMETROS DE CONFIGURAÇÃO
DE UM CONTROLADOR NEURO-FUZZY APLICADO EM UM
PROCESSO DE NEUTRALIZAÇÃO.**

Campinas, SP
Junho de 2015


AUTORA: DÉBORA ZENAIDE GORRI MAZZALI

**ANÁLISE DOS EFEITOS DOS PARÂMETROS DE CONFIGURAÇÃO
DE UM CONTROLADOR NEURO-FUZZY APLICADO EM UM
PROCESSO DE NEUTRALIZAÇÃO.**

Dissertação apresentada ao Curso de Pós-Graduação da Faculdade de Engenharia Química, da Universidade Estadual de Campinas, como parte dos requisitos exigidos para a obtenção do título de Mestra em Engenharia Química.

Orientador: PROF. DR. FLÁVIO VASCONCELOS DA SILVA

Este exemplar corresponde à versão final da dissertação defendida pela aluna Débora Zenaide Gorri Mazzali, e orientada pelo Prof. Dr. Flávio Vasconcelos da Silva.



Campinas, SP

2015

iii

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

M458a Mazzali, Débora Zenaide Gorri, 1974-
Análise dos efeitos dos parâmetros de configuração de um controlador neuro-fuzzy aplicado em um processo de neutralização. / Débora Zenaide Gorri Mazzali.
– Campinas, SP : [s.n.], 2015.

Orientador: Flávio Vasconcelos da Silva.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Sistemas fuzzy. 2. Automação. 3. controle do processos químicos - Simulação por computador. I. Silva, Flávio Vasconcelos da, 1971-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Performance evaluation of the rule base of the neuro-fuzzy controllers in the neutralization process.

Palavras-chave em inglês:

Fuzzy systems

Automation

Control of chemical processes - Computer Simulation

Área de concentração: Sistemas de Processos Químicos e Informática

Titulação: Mestra em Engenharia Química

Banca examinadora:

Flávio Vasconcelos da Silva [Orientador]

Jones Erni Schmitz

Cláudio Kiyoshi Umezu


Data de defesa: 09-06-2015

Programa de Pós-Graduação: Engenharia Química

Dissertação de Mestrado defendida por Débora Zenaide Gorri Mazzali e aprovada em 09 de Junho de 2015 pela banca examinadora constituída pelos doutores:



Prof. Dr. Flávio Vasconcelos da Silva
FEQ/UNICAMP



Prof. Dr. Jones Erni Schmitz
UNIFESP



Prof. Dr. Claudio Kiyoshi Umezu
FEAGRI/UNICAMP

A Deus, por ter me proporcionado a oportunidade de realizar e concluir este trabalho.

Aos meus pais Cláudio e Macionila, que estão sempre do meu lado em todos os momentos da minha vida.

Agradecimentos

Agradeço:

A Deus por minha existência.

Meus pais Cláudio e Macionila e também a minha filha Aline, que estão sempre ao meu lado em todos os momentos da minha vida.

Meu querido esposo Marcelo, pelo amor, paciência e incentivos durante esta jornada.

Meu amado irmão de coração Paulo Gorri, por todo apoio, ajuda e também por acreditar em minha capacidade e vitória.

Ao Prof. Dr. Flávio Vasconcelos da Silva por ter acreditado em meu potencial.

Aos meus amigos Filipe, Raphael, Saulo, Rejane e Tarcísio por todo conhecimento à mim transferido nestes anos de trabalho e por todos os dias de alegria que juntos tivemos.

Aos demais colegas a FEQ, que de alguma forma contribuíram com meu trabalho.

A Faculdade de Engenharia Química por mais esta oportunidade concedida.

Ao apoio financeiro da CAPES.

Resumo

Técnicas de Inteligência Artificial (IA) buscam imitar o raciocínio humano através da aplicação de regras lógicas, para um conjunto de dados disponível, de modo a chegar a uma forma mais eficiente de resolver problemas. Sendo um dos ramos da IA, a técnica neuro-fuzzy abordada neste estudo, será aplicada em controladores de processos que, por sua vez, são formados por estruturas de regras lógicas de difícil definição, pois existem inúmeras possibilidades de configurações que podem ser adotadas para o ajuste do controlador. Nessa perspectiva, buscou-se compreender qual a influência que cada possibilidade de configuração pode exercer no desempenho do controlador. Desta forma, verifica-se o desempenho das propostas de configuração por meio de testes de simulação numérica de modelos construídos em ambiente Matlab®/Simulink de uma planta didática de um processo de neutralização do pH. Paralelamente a este estudo, um sistema de supervisão industrial elaborado em *InduSoft Web Studio*® (IWS) foi desenvolvido para gerar os dados de treinamento do controlador, a fim de obter maior representatividade quanto à operação manual da planta num processo real. Os resultados obtidos pelos controladores avaliados mostraram que, tanto para a variável controlada pH quanto para o nível do tanque, a função de pertinência (FP) gaussiana simétrica, o método ‘OU’ (probabilístico), o método ‘E’ (produto), tipo de saída linear da FP e método de otimização híbrido potencializaram o desempenho do controlador, confirmando a importância da escolha das configurações no ajuste do controlador neuro-fuzzy para o processo estudado.

Palavras chave: fuzzy, neuro-fuzzy, controle de processo de neutralização.

Abstract

Intelligent Systems (IS) replicate the human reasoning by applying logical rules to a database to arrive at a more efficient way of solving problems. But the great problem of techniques based on rules is that it needs to have an appropriate strategy of the structure and also adjusting the settings, which both are of fundamental importance for good system performance. Given that the structures and configurations of the controller presented in the literature have not been evaluated on the impact of each configuration might have on the process control performance, so the motivation of this work it is doing this analysis, since it is really significant to control the model. Numerical simulation tests built in Matlab / Simulink environment were carried out, taking into account the various settings available in the neuro-fuzzy controller and then compared their control performances in a neutralization process model. At the same time, an industrial monitoring system in InduSoft Web Studio® (IWS) was developed to generate the training data for the controllers, in order to provide greater representation of the manual operation of the process. The simulation results of the neutralization process under the action of the settings and the rules designed to adjust the ANFIS controller showed that, to achieve the good performance of the controller, the settings and the rules should be considered, confirming its importance on the control performance of the process.

Keyword: fuzzy, neuro-fuzzy, neutralization process control.

Lista de Figuras

Figura 1: Exemplo de estrutura ANFIS (FONSECA, 2012).	8
Figura 2: Exemplo de conjuntos fuzzy (ANDRADE, 2004).	11
Figura 3: Diagrama do processo de neutralização em estudo.	22
Figura 4: Localização do método de inferência disponível no bloco ANFIS.	30
Figura 5: Localização do tipo de FP disponível no bloco ANFIS.	30
Figura 6: Localização do tipo de função de saída disponível no bloco ANFIS.	31
Figura 7: Localização do método de otimização disponível no bloco ANFIS.	31
Figura 8: Modelado processo de neutralização implementado no Matlab®/Simulink com interface de comunicação (OPC) para o <i>Indusoft (IWS)</i> .	35
Figura 9: Modelo matemático do processo implementado no Matlab®/Simulink.	35
Figura 10: Resposta dinâmica do processo em malha aberta para a variável controlada pH.	36
Figura 11: Resposta dinâmica do processo em malha aberta para a variável controlada Nível do tanque.	36
Figura 12: Interface de comunicação do processo implementado no Matlab®/Simulink com o sistema supervisor construído na plataforma Indusoft.	37
Figura 13: Tela (SVI) elaborado em <i>InduSoft Web Studio (IWS)</i> .	38
Figura 14: Seqüência de perturbações realizadas na vazão de HCl do processo de neutralização.	39
Figura 15: Ajustes manuais realizados na vazão de NH_4OH durante o controle regulatório do processo.	39
Figura 16: Abertura da válvula de saída do tanque para controle do nível.	40
Figura 17: Controle regulatório, em malha aberta, para a variável controlada pH.	40
Figura 18: Controle regulatório, em malha aberta, para a variável controlada nível do tanque.	40
Figura 19: Desempenhos dos controladores ANFIS para a variável pH.	54
Figura 20: Desempenhos dos controladores ANFIS para a variável nível do tanque.	54
Figura 21: (a) Ação do controlador para a variável manipulada $F_b [F_{\text{NH}_4\text{OH}}]$, funções triangular, trapezoidal e sino. (b) Curva ampliada no tempo 900s.	56

Figura 22: (a) Ação do controlador para a variável manipulada Fb [F_{NH4OH}], funções Gauss, Gauss2 e sigmoidal. (b) Curva ampliada no tempo 900s.	56
Figura 23: (a) Ação do controlador para a variável manipulada Fb [F_{NH4OH}], funções Dsigmoidal, Psigmoidal e P. (b) Curva ampliada no tempo 900s.	57
Figura 24: (a) Ação do controlador para a variável manipulada Av (Abert. valv.), funções triangular, trapezoidal e seno. (b) Curva ampliada no tempo 900s.	57
Figura 25: (a) Ação do controlador para a variável manipulada Av (Abert. valv.), funções Gauss, Gauss2 e sigmoidal. (b) Curva ampliada no tempo 900s.	58
Figura 26: (a) Ação do controlador para a variável manipulada Av (Abert. valv.), funções Dsigmoidal, Psigmoidal e P. (b) Curva ampliada no tempo 900s.	58
Figura 27: Controle regulatório ANFIS para variável controlada pH e função Gaussiana simétrica.	60
Figura 28: Ajuste manual vs controle ANFIS para variável manipulada Fb usando função gaussiana simétrica.	60
Figura 29: Destaque do ajuste manual vs controle ANFIS para variável manipulada Fb usando função gaussiana simétrica.	60
Figura 30: Controle regulatório ANFIS para variável controlada Abertura de Válvula (Av) e função Gaussiana simétrica.	61
Figura 31: Ajuste manual vs controle ANFIS para variável manipulada Av usando função gaussiana simétrica.	61
Figura 32: Destaque do ajuste manual vs controle ANFIS para variável manipulada Av usando função gaussiana simétrica.	61

Lista de Tabelas

Tabela 1: Funções de pertinências dos conjuntos fuzzy.....	12
Tabela 2: Especificação do reator.....	22
Tabela 3: Valores nominais das variáveis de processo.....	23
Tabela 4: Configurações do bloco ANFIS.	27
Tabela 5: Estrutura de entrada do controlador neuro-fuzzy - pH.	28
Tabela 6: Estrutura de entrada do controlador neuro-fuzzy - nível do tanque.	28
Tabela 7: Configuração das propostas para as regras do controlador ANFIS.....	32
Tabela 8: Critérios de Desempenho <i>IAE</i> , <i>ISE</i> , <i>ITAE</i> e <i>ITSE</i>	33
Tabela 9: Influência da entrada na estrutura do controlador neuro-fuzzy- variável pH.....	42
Tabela 10: Influência da entrada na estrutura do controlador neuro-fuzzy - variável nível.....	42
Tabela 11: Menor erro de treinamento entre as funções avaliadas- variável pH.	44
Tabela 12: Menor erro de treinamento entre as funções avaliadas – variável nível do tanque.....	44
Tabela 13: Resultados dos treinamentos para a variável pH e Função Triangular.....	45
Tabela 14: Resultados dos treinamentos para a variável pH e Função Trapezoidal.	45
Tabela 15: Resultados dos treinamentos para a variável pH e Função Sino.	46
Tabela 16: Resultados dos treinamentos para a variável pH e Função Gaussiana.	46
Tabela 17: Resultados dos treinamentos para a variável pH e Função Gaussiana2.	47
Tabela 18: Resultados dos treinamentos para a variável pH e Função Sigmoidal.....	47
Tabela 19: Resultados dos treinamentos para a variável pH e Função DSigmoidal.	48
Tabela 20: Resultados dos treinamentos para a variável pH e Função PSigmoidal.....	48
Tabela 21: Resultados dos treinamentos para a variável pH e Função P.	49
Tabela 22: Resultados dos treinamentos para a variável Nível e Função Triangular.....	49
Tabela 23: Resultados dos treinamentos para a var. nível e Função Trapezoidal.	50
Tabela 24: Resultados dos treinamentos para a var. nível e Função Sino.....	50
Tabela 25: Resultados dos treinamentos para a var. nível e Função Gaussiana.....	51
Tabela 26: Resultados dos treinamentos para a var. nível e Função Gaussiana2.....	51
Tabela 27: Resultados dos treinamentos para a var. nível e Função Sigmoidal.....	52
Tabela 28: Resultados dos treinamentos para a var. nível e Função DSigmoidal.....	52
Tabela 29: Resultados dos treinamentos para a var. nível e Função PSigmoidal.	53
Tabela 30: Resultados dos treinamentos para a variável nível e Função P.	53

Tabela 31: Desempenhos do controlador ANFIS para a variável pH.	54
Tabela 32: Desempenhos do controlador ANFIS para a variável nível do tanque.....	54

Nomenclatura

[HCL]	Concentração do ácido clorídrico
[NH_4OH]	Concentração de hidróxido de amônio
$\Delta e(k)$	Diferença do erro
A, B, z	Nomenclatura de um dado conjunto
A_b	Área da base do reator (tanque de mistura)
ANFIS	Sistema adaptativo de inferência neuro-fuzzy
b / w_i	Peso atribuído à rede neural
E	Entrada real do sistema
$e(k)$	Valor do erro
f_A	Função característica
F_a	Vazão da corrente ácida (HCl)
F_b	Vazão da corrente básica (NH_4OH)
F_{HCl}	Vazão do ácido clorídrico
FLT-M	Conjunto de ferramentas da lógica fuzzy
F_{NH_4OH}	Vazão de hidróxido de amônio
FP	Função de Pertinência
F_R	Vazão de refrigerante
F_S	Vazão de saída
h	Altura do reator de mistura
IA	Inteligência artificial
IAE	Integral do erro absoluto
ISE	Integral do erro quadrado
ITAE	Integral do erro absoluto no tempo

ITSE	Integral do erro quadrado no tempo
IWS	<i>Indusoft Web Studio</i>
k	Tempo de amostragem
L	Altura Reacional (nível do tanque)
LF	Lógica fuzzy
NF	Neuro-fuzzy
pH	Potencial Hidrogeniônico
PID	Controlador tipo Proporcional-Integral-Derivativo
RNA	Rede neural artificial
S	Saída real do sistema
SI	Sistemas Inteligentes
SP	Valor de referência
SVI	Sistema de Supervisão Industrial
$S_{\max}$	Valor máximo para cada ponto do domínio entre as funções de pertinência F_A e F_B do operador S-Norma de União “OU”.
S_{SA}	Soma algébrica do operador S-Norma de Intersecção “OU”.
$T_{\min}$	Valor mínimo para cada ponto do domínio entre as funções de pertinência F_A e F_B do operador T-Norma de Intersecção “E”.
T_{PA}	Produto algébrico do operador T-Norma de Intersecção “E”.
V_r	Volume reacional da mistura
wtaver	Média Ponderada
wtsum	Soma Ponderada
X / μ_A	Universo de discurso
x_i	Entrada (<i>i</i>)
φ	Função de Ativação
N/A	Dados não avaliados

Sumário

<i>Capítulo 1</i>	1
1.1 Introdução	1
1.2 Hipótese	3
1.3 Objetivos.....	4
<i>Capítulo 2</i>	5
Fundamentação Teórica e Revisão Bibliográfica.....	5
2.1Fundamentação Teórica.....	5
2.1.1 Sistemas neuro-fuzzy (ANFIS)	5
2.1.2Sistemas fuzzy	9
2.1.3 Propriedades dos conjuntos fuzzy	10
2.1.3.1Interface de fuzificação	10
2.1.3.2 Variáveis lingüísticas vs Base de conhecimento	11
2.1.3.3 Função de Pertinência.....	12
2.1.3.4 Lógica para a Tomada de Decisões	14
2.1.3.5 Defuzificação.....	16
2.2 Revisão Bibliográfica	16
<i>Capítulo 3</i>	21
Simulação Computacional.....	21
3.1 Processo de neutralização do pH	21
3.1.2 Modelo matemático do processo de neutralização	23
3.2 Base de conhecimento especialista.....	24
3.2.1 Sistema Supervisório - <i>InduSoft Web Studio</i> [®] (IWS).....	25
3.2.2 Sistema de Comunicação.....	26
3.3 Simulação das configurações ANFIS	27
3.3.1 Estrutura de entrada do controlador ANFIS	27
3.3.2 Configuração da base de regras ANFIS	29
3.3.3 Desempenho do sistema de controle	33
<i>Capítulo 4</i>	34
Resultados e Discussões	34

4.1 Processo de neutralização do pH	34
4.2 Sistema de supervisão Virtual	37
4.3 Estrutura de entrada do controlador ANFIS	41
4.4 Configuração da Base de regras ANFIS	43
4.5 Desempenho do sistema de controle	54
<i>Capítulo 5</i>	62
5.1 Conclusão	62
5.2 Sugestões para trabalhos futuros	64
<i>Referências Bibliográficas</i>	65

Capítulo 1

1.1 Introdução

Na química, um dos principais desafios para o controle do pH de um processo de neutralização é dominar a não linearidade que interfere no ganho do processo reduzindo a precisão de controle em processos industriais tais como: tratamento de efluentes ou processos químicos que envolvam reações químicas. Algoritmos baseados em controladores convencionais são comumente empregados para controlar automaticamente o pH, porém, estes exigem numerosas tentativas de ajuste fino demandando tempo, matéria prima, mão de obra e, afetando a qualidade dos produtos e a produtividade. Por conseguinte, as limitações apresentadas pelo controlador PID proporcionam maiores custos e por vezes, baixa eficiência. Para resolver estes problemas, muitos pesquisadores têm estudado sobre métodos efetivamente mais precisos e eficientes de controle, baseados nos conceitos de Inteligência Artificial.

Do ponto de vista matemático, modelar sistemas não lineares pode ser complicado, tomar tempo e, em alguns casos, há necessidade de se levar em consideração: (i) a validade de hipóteses simplificadoras, (ii) a definição de um ponto de operação e sua linearização, (iii) a obtenção de parâmetros do sistema, (iiii) a necessidade de um modelo complexo do processo. Estes fatos nos remetem a uma maior aplicação e desenvolvimento de técnicas avançadas de controle que, sendo ramo da inteligência artificial (IA), imitam a experiência humana adaptando-se de maneira

generalizada e adequada aos modelos matemáticos complexos ou não lineares. (SIVAKUMAR, SAHANA e SAVITHA, 2012).

No campo da engenharia, a lógica fuzzy deve ser vista como uma interface vantajosa e fácil de usar para desenvolver programas de controle, ajudando os engenheiros a concentrar-se nos objetivos funcionais do processo, e não sobre a matemática. Adaptar os parâmetros de controle fuzzy para obter o melhor desempenho é de vital importância durante a implementação prática do controlador. Com isso, técnicas avançadas da IA tais como, redes neurais artificiais (RNA) e lógica fuzzy (FL) tem sido cada vez mais aplicada em muitos campos da engenharia química desde sua introdução como uma ferramenta matemática auxiliar para resolver problemas de sistemas com não linearidade acentuada (MAMDANI e ASSILIAN, 1975) e (TAKAGI e SUGENO, 1985).

Embora a lógica fuzzy permita modelar sistemas utilizando o conhecimento e a experiência humana baseada em regras “SE ..., ENTÃO”, este método nem sempre é suficiente por si só e isto também vale para as redes neurais que só lidam com dados numéricos em vez de expressões lingüísticas. Sivakumar, Sahana e Savitha (2012), em sua pesquisa com sistemas ANFIS (*adaptive neuro fuzzy inference system*), demonstraram que esta deficiência pode ser superada através da combinação dos benefícios de ambos os métodos, todavia, a união das técnicas apresentadas anteriormente preservam suas estruturas baseadas em regras e a geração adequada da sua estrutura não é uma tarefa trivial, pois existem inúmeras possibilidades de configurações que podem ser adotadas para o ajuste do controlador.

Segundo Simões e Shaw (2007), o problema dos sistemas baseados em regras é que necessitam dispor de uma estratégia adequada da sua estrutura e o ajuste dos parâmetros torna-se de fundamental importância para o desempenho do sistema de controle e por consequência, a eficácia dos componentes do controlador podem ser verificadas em termos de precisão do controle. A construção da base de regras representa os aspectos fundamentais de todas as ações teóricas e práticas de um Sistema Inteligente (SI), pois é na base de regras que se caracteriza uma solução aproximada dos problemas com presença de incertezas contidas nas diversas áreas do conhecimento.

Normalmente, as pesquisas apresentam várias metodologias de avaliação ou algoritmos de processamento, que permitem ao usuário focalizar sua atenção nas regras que mais se destacam dentro do conjunto gerado, ou seja, nas funções de pertinência que podem, muitas vezes, não representar a maximização do desempenho do modelo em certos estudos. Surge então, a necessidade de se investigar as configurações que complementam o desempenho destas regras que se baseiam a inteligência artificial, cujo interesse aqui está nos controladores neuro-fuzzy, capazes de lidar com não linearidades de modo direto.

É evidente que a alteração dos parâmetros estruturais do controlador, ou seja, as configurações de funções de pertinência dos valores lingüísticos, os métodos de raciocínio difuso (operadores) e o número de regras, afetam a sintonia das funções de entrada e de saída. Para se criar um controlador, precisa-se definir o tipo da função e ajustar as configurações do controlador que indicam o desempenho do modelo (LOTFI e TSOI, 1994). Porém, compreender qual a contribuição que cada estratégia de regras e configurações adotadas pode propiciar ao controle do modelo não está evidente e torna-se a motivação deste trabalho.

Paralelamente a este estudo, um sistema virtual de supervisão industrial foi desenvolvido para gerar os dados de treinamento dos controladores. Esse sistema virtual criado busca imitar o controle manual realizado pelo especialista do processo e representa as informações presentes numa planta física real de um processo de neutralização.

Como motivação deste trabalho, buscou-se então compreender qual a influência que cada possibilidade de configuração pode produzir no desempenho do controlador. A metodologia, resultados e análises são apresentados e discutidos a seguir.

1.2 Hipótese

Todos os parâmetros de configuração de um controlador neuro-fuzzy possuem influências determinantes no desempenho de controle aplicado em um processo químico de neutralização.

1.3 Objetivos

Este trabalho tem por objetivo geral analisar os efeitos que cada conjunto de configurações adotadas em um controlador neuro-fuzzy pode propiciar ao desempenho de controle regulatório de um processo de neutralização, usando conhecimento especialista baseado em um software de supervisão.

Como objetivos específicos, são propostos:

- Implementar no software *Matlab*[®]/*Simulink* um modelo que represente de maneira realista o processo de neutralização;
- Obter o conhecimento especialista do processo (base de dados) para o treinamento dos controladores neuro-fuzzy, através da interação do modelo do processo construído no *software Matlab*[®] com um simulador virtual de processo desenvolvido em plataforma *InduSoft Web Studio*[®] (*IWS*);
- Determinar a arquitetura mais adequada, quanto ao desempenho de controle, para os controladores ANFIS;
- Simular o processo de neutralização utilizando vários controladores neuro-fuzzy com diferentes configurações;
- Comparar os resultados das simulações obtidas para as várias configurações dos controladores neuro-fuzzy por meio dos cálculos dos parâmetros de erro (ISE, ITSE, IAE e ITAE);
- Obter os parâmetros de configurações dos controladores neuro-fuzzy com maior contribuição ao desempenho do controle regulatório aplicado a um processo de neutralização.

Capítulo 2

Fundamentação Teórica e Revisão Bibliográfica

Neste capítulo será apresentada a técnica avançada de controle neuro-fuzzy (ANFIS). Porém, para estudar os efeitos que o conjunto de parâmetros utilizados para se projetar controladores neuro-fuzzy podem exercer sobre o controle de um processo de neutralização, faz-se necessário um detalhamento sobre teoria da lógica fuzzy (LF) do ponto de vista matemático, devido ao foco deste estudo estar nas configurações dos parâmetros. Na sequência, uma revisão bibliográfica sobre dos estudos já realizados que contemplam as relações entre as configurações dos controladores fuzzy e neuro-fuzzy e o desempenho produzido no controlador.

2.1 Fundamentação Teórica

2.1.1 Sistemas neuro-fuzzy (ANFIS)

Como mencionado anteriormente, as técnicas de inteligência artificial têm sido bastante aplicadas em sistemas não lineares. Dentre as técnicas inteligentes estão as redes neurais artificiais (RNAs), os sistemas nebulosos (LF) e os sistemas neuro-fuzzy (ANFIS).

Uma das maiores dificuldades na utilização de redes neurais artificiais é encontrar a configuração adequada de sua estrutura para que ela apresente resultados satisfatórios, ou seja, descobrir qual a função de ativação dos neurônios de cada camada, quantas camadas e quantos neurônios em cada camada deve ter a rede neural pode se tornar um trabalho árduo e cansativo.

Nos sistemas que se utilizam da lógica fuzzy, deve-se descobrir o tipo, a quantidade e o formato das funções de pertinência a serem utilizadas e definir as regras e os operadores para o tratamento de suas entradas. Caso sejam utilizados modelos nebulosos de interpolação, deve-se determinar o grau e os coeficientes dos polinômios das funções de saída.

Na busca constante por técnicas que atendam as crescentes necessidades da indústria química, a mistura de técnicas vem ganhando espaço. Normalmente, uma técnica híbrida tenta combinar as vantagens das técnicas misturadas, de forma a gerar um sistema ainda melhor. Por esta razão, a metodologia ANFIS proposta por (JANG, 1993) é utilizada para adaptar os parâmetros do controlador fuzzy de acordo com os dados reais relacionados a problemas específicos, no caso a RNA, de forma que os algoritmos de aprendizado possam ser utilizados para ajustar o sistema de inferência de acordo com as entradas e saídas dos dados (FONSECA, 2012). Como definição geral, os sistemas neuro-fuzzy são sistemas que combinam as vantagens das redes neurais, no que se refere ao aprendizado, com o poder de interpretação lingüística dos sistemas de inferência fuzzy.

Em contraste aos sistemas fuzzy, as redes neurais não consideram o operador humano para prever o comportamento do sistema, em vez disso, o comportamento do sistema está geralmente contido em conjuntos de dados, que são utilizados para o treinamento e aprendizado da rede. Uma vez aprendido o comportamento do sistema, as redes neurais podem então extrair tais regras e passá-las ao controlador fuzzy, que usa a teoria de conjuntos fuzzy, como ferramental matemático para se lidar com as regras lingüísticas. Assim, a combinação destas duas tecnologias pode conter uma resposta completa aos problemas de projeto de sistemas inteligentes (SIMÕES e SHAW, 2007).

Uma das vantagens da técnica híbrida mais evidentes em relação à técnica das redes neurais artificiais é a maneira que traduz o conhecimento. Enquanto nas RNAs o conhecimento é codificado em forma de pesos, cujas ações são de difícil interpretação, no ANFIS o conhecimento é codificado em uma estrutura que possui certa aproximação da lógica utilizada por humanos.

O ANFIS desenvolvido por (JANG, 1993), pode ser caracterizada como sendo uma rede neural artificial de seis camadas interligadas através de pesos unitários, em que cada camada é responsável por uma operação que resultará em uma saída equivalente à encontrada, em uma determinada etapa de um sistema nebuloso do tipo Takagi-Sugeno (JANG, 1993), (JANG e GULLEY, 1995). Trata-se, portanto, de uma técnica híbrida, de inteligência artificial, que infere conhecimentos utilizando os princípios da lógica nebulosa e acrescenta a essa estrutura a possibilidade de aprendizagem inerente às redes neurais artificiais. Dessa forma, esse sistema híbrido resolve um dos maiores problemas da utilização da lógica nebulosa que é a sintonia das funções de entrada e de saída. Sob o ponto de vista das redes neurais artificiais, o ANFIS torna mais simples a definição de sua arquitetura.

A restrição dessa técnica híbrida é a mesma para os sistemas fuzzy que, devido ao problema combinatório das regras que podem alcançar um número muito elevado, não devem ser utilizados em sistemas com muitas entradas, principalmente se o universo de discurso delas for muito particionado. Supondo-se, por exemplo, uma rede neuro-fuzzy com quatro variáveis de entrada e cada uma delas tendo seu universo de discurso dividido em três conjuntos nebulosos, pode-se chegar a um total de 81 (3^4) regras. Supondo-se agora que se tenha 10 entradas, com três variáveis lingüísticas para cada entrada, chega-se a um total de 59.049 (3^{10}) regras, o que torna impraticável a utilização desses sistemas (PAGLIOSA, 2003).

A Figura 1 ilustra um ANFIS com duas entradas, duas funções de pertinência para cada entrada e quatro funções de saída. A primeira camada do sistema neuro-fuzzy é responsável pela interpretação dos dados e assim como na primeira camada de uma rede neural artificial, também não ocorrem processamentos, portanto não há neurônios. Devido a isso alguns autores não consideram essa etapa como uma camada, enquanto outros a denominam de camada de entrada.




Figura 1: Exemplo de estrutura ANFIS (FONSECA, 2012).

As informações de entrada são codificadas na segunda camada do ANFIS, ou seja, os valores das entradas são operados por funções de pertinência que indicarão o grau de compatibilidade de cada entrada com os respectivos conjuntos de entrada nebulosos. Portanto os neurônios dessa camada possuem como função de ativação funções de pertinência. Os parâmetros dessas funções serão ajustados por um método de otimização ou algoritmo de treinamento escolhido.

A operação de interseção entre as funções de pertinência de entrada é realizada na terceira camada, de acordo com o operador escolhido. Os neurônios dessa camada possuem, portanto, funções de ativação fixas, não ajustáveis.

Na quarta camada da estrutura ilustrada na Figura 1, são realizadas as normalizações das saídas da camada anterior. Por realizar apenas essa operação, ela pode ser incorporada ao neurônio da última camada, ficando o sistema ANFIS com apenas cinco camadas, ou ainda se pode colocá-la como apenas um neurônio na última camada, permanecendo o sistema ANFIS com seis camadas. A função de ativação dos neurônios dessa camada é descrita na Equação 1.

$$f(w) = \frac{w_i}{\sum_{j=1}^m w_j} \quad 1)$$

onde, w_i é a saída do neurônio i da camada anterior.

Os neurônios da quinta camada são ativados por funções do tipo Sugeno, que são combinações de ordem dos sinais de entrada, portanto essa camada é

responsável pelo cálculo dos valores dos conseqüentes das regras. Os parâmetros dessas funções também podem ser ajustados pelo método de otimização ou algoritmo de treinamento escolhido. A Equação 2 descreve uma função do tipo Sugeno, de primeira ordem, para a estrutura ilustrada na Figura 1. Em muitos casos, o termo independente é desprezado, reduzindo o número de parâmetros a serem ajustados.

$$f(x, y) = \alpha x + \beta y + \gamma \quad (2)$$

Finalmente, a última camada da estrutura representada na Figura 1 realiza o somatório das saídas da camada anterior, apresentando então a saída do ANFIS.

Dessa forma, em um ANFIS, o aprendizado consiste no ajuste dos parâmetros das funções de ativação dos neurônios da segunda e quinta camadas, ou seja, consiste em otimizar os parâmetros das funções de entrada e de saída de um sistema nebuloso Takagi-Sugeno. Isso ocorre porque os neurônios das demais camadas possuem funções de ativações sem parâmetros ajustáveis. Da mesma maneira que ocorre nas redes neurais artificiais, o treinamento pode ser realizado com a aplicação de métodos de otimização ou de aprendizagem baseados no gradiente, como a retropropagação do erro.

A seguir, será apresentado um detalhamento sobre a lógica fuzzy mostrando todas as suas particularidades que devem servir como base para a configuração do controlador proposto e que são fundamentais para o entendimento deste estudo.

2.1.2 Sistemas fuzzy

A ideia básica de um sistema fuzzy, é a existência do que é chamado de conjuntos fuzzy. Esses conjuntos são funções que mapeiam um valor escalar em um número limitado entre 0 e 1, que indica o grau de pertinência desse valor ao conjunto. De maneira geral, o processo de inferência passa por diferentes etapas, que serão detalhadas a seguir:

- **Fuzificação:** Nesta etapa é feita a transformação das variáveis de entrada do problema em valores fuzzy entre 0 e 1.

- **Regras:** As regras podem ser fornecidas por especialistas ('Se...Então...') ou podem ser extraídas de dados numéricos treinados pelas redes neurais.
- **Inferência:** Nessa etapa, as regras são aplicadas sobre os valores de entrada já "fuzificados", fazendo portanto, o mapeamento dos conjuntos fuzzy. Aqui também é determinado como as regras são ativadas e combinadas, e contempla o sistema de tomada de decisão.
- **Defuzificação:** Aqui, as regiões resultantes do processo de inferência são convertidas em valores para a variável de saída do sistema. Esta etapa corresponde à ligação funcional entre as regiões fuzzy e o valor esperado.

2.1.3 Propriedades dos conjuntos fuzzy

O entendimento das propriedades dos conjuntos fuzzy são extremamente importantes para a concepção de sistemas que se utilizam desta lógica, pois os cálculos proposicionais, por exemplo, são baseados nestas propriedades (operações). Mesmo nos casos da técnica neuro-fuzzy, onde os cálculos proposicionais são formados pela RNA, algumas destas propriedades podem ser alteradas e influenciam no desempenho do controlador com um todo. A seguir, serão descritas as propriedades que participam deste estudo e que serão avaliadas.

2.1.3.1 Interface de fuzificação

A fuzificação consiste em transformar uma quantidade precisa em quantidade fuzzy. Nesta interface, os valores observados das variáveis de entrada são associados ao respectivo universo de discurso, permitindo uma avaliação do grau de pertinência aos conjuntos fuzzy associados a cada variável (ZADEH, 1973). Esse valor deve estar necessariamente limitado entre 0 a 1. O grau de pertinência 0 significa que o valor não pertence ao conjunto, enquanto o grau de pertinência 1 indica que o valor é uma representação completa do conjunto.

2.1.3.2 Variáveis lingüísticas vs Base de conhecimento

Pode-se considerar uma *variável lingüística* (ou fuzzy) como um conjunto de informações utilizado para representar de modo subjetivo – e, portanto, lingüístico – um conceito ou uma variável de um dado problema. Uma variável lingüística, diferentemente de uma variável numérica, admite apenas valores definidos na linguagem fuzzy que está utilizando-se dela. Por exemplo: *Nível é alto*. A variável ‘Nível’ está recebendo o valor ‘alto’, que é um dos conjuntos fuzzy definidos para esta variável (Figura 2).




Figura 2: Exemplo de conjuntos fuzzy (ANDRADE, 2004).

Os modificadores são termos ou operações que modificam a forma dos conjuntos fuzzy (ou seja, a intensidade dos valores fuzzy), podendo-se citar, por exemplo, os advérbios *muito*, *pouco*, *extremamente*, *quase*, *mais ou menos*, entre outros. Estes podem ser classificados em *aumentadores*, quando aumentam a área de pertinência de um conjunto fuzzy, ou, analogamente, *diminuidores*, quando diminuem a área de pertinência de um conjunto fuzzy.

No caso deste estudo, a base de regras aqui tratada é formada pela rede neural que extrai as informações do comportamento do sistema para então passá-las ao controlador fuzzy, que usa a teoria de conjuntos fuzzy, como ferramental matemático para se lidar com as tais regras lingüísticas. Com isso, a elaboração das variáveis lingüísticas, ou seja, os qualificadores (muito, pouco, alto, baixo, ...), as conexões lógicas: do tipo E/OU para criar a relação entre as variáveis e as implicações do tipo: Se A então B; ficam a cargo das redes neurais.

2.1.3.3 Função de Pertinência

A função de pertinência associa cada elemento do conjunto um grau de pertinência ao mesmo, isto é, indica o quanto um elemento pertence a ele. No item anterior, a considerada *função característica* f_A representava a função de pertinência. Como se pode perceber, para os conjuntos clássicos, f_A pode assumir somente dois valores, 0 ou 1, enquanto que nos casos dos conjuntos fuzzy, além de 0 e 1, a função de pertinência comporta além dos valores compreendido entre os mesmos, isto é, assume valores do intervalo $[0, 1]$.

A função de pertinência delinea os limites de um conjunto fuzzy, podendo assumir várias formas gráficas, sendo que o contexto de aplicação é que determinará se uma forma específica é adequada ou não àquela situação (JANG e GULLEY, 1995). A caixa de ferramenta que opera a lógica fuzzy no *software Matlab®/Simulink*, chamado de *Fuzzy Logic Toolbox - FLT- M* apresenta onze tipos de funções de pertinência (FP ou mf - *membership function*): triangular (trimf), trapezoidal (trapmf), gaussiana simétrica (gaussmf), gaussiana não simétrica (gauss2mf), sino (gbellmf), sigmoidal (sigmf), diferença entre duas funções sigmoidais (dsigmf), produto entre duas funções sigmoidais (psigmf), função spline Z (zmf), função spline S (smf), produto entre duas funções spline, conhecida como Função P (pmf). As equações que representam estas funções de pertinência estão representadas na Tabela 1.

Tabela 1: Funções de pertinências dos conjuntos fuzzy.



Triangular (trimf) 	$f(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right)$ Onde, a forma triangular é uma função do vetor x e depende de três parâmetros escalares: a, b e c. Os parâmetros a e c localizam-se na base do triângulo e o parâmetro b no pico do triângulo. Os parâmetros são listados nesta ordem: $y = \text{trimf}(x, [a \ b \ c])$
Trapezoidal (trapmf) 	$f(x; a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{d-x}{d-c}\right), 0\right)$ Onde, a forma trapezoidal é uma função do vetor x e depende de quatro parâmetros escalares: a, b, c e d. Os parâmetros a e d localizam-se na base maior do trapézio e os parâmetros b e c localizam-se na base menor deste. Os parâmetros são listados nesta ordem: $y = \text{trapmf}(x, [a \ b \ c \ d])$.

Tabela 1: Funções de pertinências dos conjuntos fuzzy (Continuação).










Gaussiana simétrica (gaussmf) 	$f(x; \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}}$ Onde, a forma gaussiana simétrica é uma função do vetor x e depende de dois parâmetros σ (variância) e c (média). Os parâmetros para função gaussiana simétrica representam os parâmetros σ e c listados nesta ordem: $y = \text{gaussmf}(x, [\sigma \ c])$.
Gaussiana não simétrica (gauss2mf) 	$f(x; \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}}$ Onde, a forma gaussiana não simétrica é uma função do vetor x e depende de dois parâmetros sig e c. A função gauss2 é a combinação dos dois argumentos destes dois parâmetros, ou seja, $[\text{sig1}, c1 \text{ e } \text{sig2}, c2]$. O primeiro argumento determina a forma esquerda da curva e o segundo argumento determina a forma direita da curva. Sempre que $c1 < c2$, a função gaussiana não simétrica atinge o valor máximo de 1. Caso contrário, o valor máximo será inferior a 1. Os parâmetros são listados nesta ordem: $y = \text{gauss2mf}(x, [\text{sig1} \ c1 \ \text{sig2} \ c2])$.
Sino (gbellmf) 	$f(x; a, b, c) = \frac{1}{1 + \left \frac{x-c}{a} \right ^{2b}}$ Onde, a forma sino generalizado é uma função do vetor x depende de três parâmetros a, b e c. O parâmetro b é normalmente positivo e o parâmetro c localiza o centro da curva. Os parâmetros são listados nesta ordem: $y = \text{gbellmf}(x, [a \ b \ c])$.
Sigmoidal (sigmf) 	$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$ Onde, a forma sigmoidal é uma função do vetor x e depende de dois parâmetros a e c. Dependendo do sinal do parâmetro a, a função sigmoidal torna-se aberta para a direita ou para a esquerda. Esta forma é adequada para representar variáveis tais como "muito grande" ou "muito negativo". Os parâmetros são listados nesta ordem: $y = \text{sigmf}(x, [a \ c])$.
Diferença sigmoidal (dsigmf) 	$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$ Onde, a forma diferença sigmoidal é uma função do vetor x e depende do quatro parâmetros $a1$, $c1$, $a2$ e $c2$. A diferença entre duas destas funções apresentadas, ou seja, $[f1(x; a1, c1) - f2(x; a2, c2)]$ é a função conhecida por diferença sigmoidal. Os parâmetros são listados nesta ordem: $y = \text{dsigmf}(x, [a1 \ c1 \ a2 \ c2])$.
Produto sigmoidal (psigmf) 	$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$ Onde, a forma produto sigmoidal é uma função do vetor x e depende do quatro parâmetros $a1$, $c1$, $a2$ e $c2$. O produto entre duas destas funções apresentadas, ou seja, $[f1(x; a1, c1) \cdot f2(x; a2, c2)]$ é a função conhecida por produto sigmoidal. Os parâmetros são listados nesta ordem: $y = \text{psigmf}(x, [a1 \ c1 \ a2 \ c2])$.
Função Z (zmf) 	$f(x; a, b) = \begin{cases} 1, & x \leq a \\ 1 - 2\left(\frac{x-a}{b-a}\right)^2, & a \leq x \leq \frac{a+b}{2} \\ 2\left(\frac{x-b}{b-a}\right)^2, & \frac{a+b}{2} \leq x \leq b \\ 0, & x \geq b \end{cases}$ Onde, a forma 'Z' é uma função do vetor x e depende de dois parâmetros a e b que estão localizados nos extremos da parte inclinada curva. A função Z é baseada na função spline de interpolação e usa de aproximação polinomial por partes, gerando um polinômio interpolador para cada intervalo entre nós. Os parâmetros são listados nesta ordem: $y = \text{zmf}(x, [a \ b])$.

Tabela 1: Funções de pertinências dos conjuntos fuzzy (Continuação).

Função S (smf) 	$f(x; a, b) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-b}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-a}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & x \geq b \end{cases}$ Onde, a forma 'S' é uma função do vetor x e depende de dois parâmetros a e b que estão localizados nos extremos da parte inclinada curva. A função S é baseada na função spline de interpolação, porém de forma inversa a função zmf. Os parâmetros são listados nesta ordem: $y = \text{smf}(x, [a \ b])$.
Função P (pmf) 	$f(x; a, b) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-b}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - 2 \left(\frac{x-c}{d-c} \right)^2, & c \leq x \leq \frac{c+d}{2} \\ 2 \left(\frac{x-d}{d-c} \right)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & x \geq d \end{cases}$ Onde, a forma 'P' é avaliada nos pontos determinados pelo vetor x. Os parâmetros a e d estão localizados na base maior da curva, enquanto que b e c estão localizados na base menor da curva. A função 'P' é o produto das funções smf e zmf. Os parâmetros são listados nesta ordem: $y = \text{pmf}(x, [a \ b \ c \ d])$.

2.1.3.4 Lógica para a Tomada de Decisões

As lógica para a tomada de decisão dependerá da base de regras construída, a qual pode ser formada por conhecimento especialista ('Se...Então...') ou podem ser extraídas de dados numéricos usando redes neurais. No primeiro caso, a tomada de decisão contempla as estruturas baseadas nas funções de implicação fuzzy e em operadores de composição para a definição da saída fuzzy do controlador e podem ser definidos com o uso dos chamados controladores baseados na metodologia de Mamdani. Já o segundo caso dispensa a definição de funções de implicação e operadores para a inferência e podem ser definidos com o uso dos chamados controladores baseados na metodologia de Takagi-Sugeno (ANDRADE, 2009).

A técnica neuro-fuzzy tratará então dos chamados controladores fuzzy de Sugeno, que por sua vez, consistem numa simplificação do controlador fuzzy de Mamdani. A parte conseqüente de cada regra é definida como uma função das variáveis lingüísticas de entrada, assim, não se tem mais um conjunto fuzzy como resultado de cada regra, mais sim um valor numérico. Com isso, não existe a necessidade de se utilizar uma função de implicação. No controlador Sugeno, uma regra pode ser escrita da seguinte maneira:

$$\text{Regra } (R_i): \text{SE } x \text{ é } A \text{ e } y \text{ é } B, \text{ ENTÃO } z = f_i(x, y) \quad (3)$$

A agregação e a defuzificação acontecem da seguinte forma: os resultados das regras são agregados como somas ponderadas das ações de controle correspondentes a cada regra, em que o peso de cada regra é o grau de pertinência calculado para o antecedente da regra, e, com isso, obtém-se um valor numérico final.

O valor de z pode ser determinado como um valor constante, que pode ser interpretado como um conjunto fuzzy com a característica especial de apresentar um único valor com pertinência igual a um de todos os demais com pertinência zero. Este tipo de conjunto é denominado *singleton*, e o seu emprego permite a definição de regras com valores de saída que representam uma classificação da resposta do controlador, sem alterar a forma simplificada da determinação da resposta final do controlador (ANDRADE, 2009).

De acordo com Jaques *et al.* (2002), existem vários métodos para se realizar a implementação dos operadores e da função de implicação. Na *Fuzzy Logic Toolbox - FLT-M* do *software* Matlab®/Simulink, usada como referencia para desenvolvimento da presente pesquisa, estão disponibilizadas para uso direto do usuário duas operações para se implementar tanto o operador “E / OU” quanto a função de implicação (intersecção ou união). Neste estudo, são considerados as propriedades dos operadores “E / OU”, pois as funções de implicação para a técnica híbrida ficam desabilitadas. São eles:

- a) Operadores T-Norma de Intersecção “E” (ou *mínimo*, *min.*) e produto algébrico (*prod.*). Na operação intersecção, a função de pertinência resultante da intersecção de dois conjuntos *fuzzy* de entrada A e B, com funções de pertinências F_A e F_B , respectivamente, é definida como o valor mínimo, para cada ponto do domínio, entre as funções de pertinência F_A e F_B . Já o produto algébrico, corresponde ao produto das funções de pertinência dos conjuntos *fuzzy* de entrada.

$$\text{Mínimo} - T_{min}(a, b) = \text{Min}(a, b) = a \cap b = a \text{ 'E' } b \quad (4)$$

$$\text{Produto Algébrico} - T_{PA}(a, b) = ab \quad (5)$$

- b) Operadores S-Norma de União “OU”(ou *máximo*, *max.*) e a soma algébrica (*probor*, probabilístico). Na operação união, a função de pertinência resultante da união de dois conjuntos *fuzzy* de entrada A e B, com funções de pertinência F_A e F_B , respectivamente, é definida como o valor máximo, para cada ponto do domínio,

entre as funções de pertinência F_A e F_B . A soma algébrica, por sua vez, corresponde a soma das funções de pertinências dos conjuntos *fuzzy* de entrada menos o produto destas funções.

$$\text{Máximo} - S_{max}(a,b) = \text{Max}(a,b) = a \cup b = a \text{ 'OU' } b \quad (6)$$

$$\text{Soma Algébrica} - S_{SA}(a,b) = a + b - ab \quad (7)$$

2.1.3.5 Defuzificação

Após ter passado pela interface de fuzificação e pela unidade lógica de tomada de decisão, os produtos obtidos ainda são conjuntos fuzzy. É necessário então que estes sejam agregados de forma que a saída corresponda a um único conjunto fuzzy para cada variável de saída, formado por todos os possíveis valores de controle e seus respectivos graus de pertinência. Para o controlador Sugeno, a interface apresentada pelo *Matlab*[®]/*Simulink* é a mesma, entretanto, os campos que definem o modo de implementação da função de implicação, o modo de implementação de agregação e a opção de soma ponderada (*wtsum*) ficam desativados, e o campo do método de defuzificação só pode ser preenchido de uma maneira, ou seja, com a média ponderada (*wtaver*).

2.2 Revisão Bibliográfica

Na ânsia por compreender os efeitos das configurações dos parâmetros dos controladores fuzzy e neuro-fuzzy para então encontrar a melhor configuração de maneira prática e precisa, pesquisadores ao longo dos anos tem estudado várias metodologias de avaliação ou algoritmos de processamento que permitem destacar o melhor conjunto de regras para o ajuste do controlador.

Ship-Peng-Lo (2003) estudou dois tipos diferentes de função de pertinência: função triangular e função trapezoidal de um controlador ANFIS, a fim de comparar as precisões alcançadas nos testes de medição da rugosidade de superfícies metálicas. A comparação indicou que ambas alcançaram precisão muito satisfatórias. Porém, a

função triangular alcançou uma precisão de resposta maior que a função trapezoidal, demonstrando a importância na escolha dos parâmetros do controlador ANFIS.

Em um trabalho sobre controle de tráfego, a necessidade de conhecer os efeitos dos parâmetros do controlador semafórico fuzzy também foi explorada. Na expectativa de melhorar o desempenho de controle da operação, Andrade e Jacques (2005), compararam um controlador de base de regras particionada com um controlador de base única, criados a partir das regras existentes em um controlador fuzzy original. Os resultados da simulação da operação do tráfego sob a atuação de controladores de configurações diferentes mostraram que a estrutura do conjunto de regras do controlador fuzzy impactou de modo significativo tanto na resposta do controlador quanto no desempenho do controle de tráfego.

Mais recentemente, Ho *et al.* (2009) aplicou algoritmo genético no mesmo tipo de processo de fresagem que Ship-Peng-Lo (2003) estudou. Os pesquisadores utilizaram o algoritmo genético para destacar a função de pertinência do controlador ANFIS que proporcionasse maior desempenho na ação de controle para obter maior precisão em testes de medição da rugosidade de superfícies metálicas. Com base no critério de minimização do erro médio quadrático (RMSE), os resultados experimentais mostram que o algoritmo proposto encontrou uma função de pertinência que superou o desempenho da função de pertinência triangular já utilizada em termos de precisão, confirmando a importância do efeito das configurações do controlador no desempenho do modelo.

Usta, Akyaz e Altas (2011), investigaram qual a função de pertinência teria maior eficácia sobre um modelo simulado, que neste estudo, tratou-se de um sistema de rastreamento solar. Várias funções de pertinência foram testadas e os resultados dos desempenhos das funções foram comparados entre si. Os resultados das simulações adotando a função triangular apresentaram bons desempenhos e bem aceitáveis para o controle fuzzy proposto. Observou-se também que, as funções de Gauss e de Cauchy foram superiores em desempenho quando comparados a função do tipo Sino e, as demais funções, apresentaram-se inferiores aos resultados da função do tipo Sino. Portanto, o controle da posição do rastreamento solar mais sensível foi verificado ao utilizar a função de pertinência triangular. Os resultados obtidos também evidenciaram que o uso de tais controladores também aumentaram a velocidade do tempo de resposta.

Outro algoritmo genético, nomeado de controlador genético fuzzy tipo-2 (T2GFLG), foi desenvolvido por um grupo de pesquisadores na busca por encontrar o melhor ajuste das configurações dos controladores fuzzy. O grupo propôs uma forma de projetar tais funções de pertinência e conjuntos de regras fuzzy automaticamente, sem a dependência de especialistas humanos (SHILLT *et al.*, 2011). Como resultado, encontraram um método adaptativo de auto aprendizagem capaz de gerar parâmetros de funções de pertinências considerados ideais, estabelecendo regras de controle fuzzy confiável, sem qualquer conhecimento, a priori, pelo especialista sobre o processo. A metodologia aplicada se baseia em otimizar a base de regras, encontrando assim, um conjunto ideal de parâmetros para o problema a ser resolvido.

Mohamad *et al.* (2011), apresentaram um estudo usando controlador fuzzy em sistemas térmicos de aquecimento. Os sistemas foram modelados matematicamente e simulados usando *Matlab®/Simulink*. Cinco tipos de funções de pertinência foram projetadas e testadas, sendo: gaussiana simétrica, triangular, trapezoidal, trapezoidal/triangular e sino generalizado, e posteriormente comparadas considerando quatro diferentes base de regras (3x3, 5x5, 7x7 e 9x9). Os resultados foram comparados com base no *overshoot*, estabilidade e desempenho IAE. Os resultados apontaram que controlador fuzzy usando função trapezoidal/triangular combinado e função triangular com base de regra 3x3 alcançaram as respostas mais satisfatórias.

Outro grupo de estudos, de Nunes e Ribeiro (2013), testaram a confiabilidade do sistema ANFIS na classificação binária de ataques a redes de computadores, problema crescente em nosso tempo. Para isso, foram testados três modelos ANFIS baseados em três funções de pertinência, trapezoidal, gaussiana e produto sigmoidal, para a base de dados pública. Os resultados, calculados a partir do desvio quadrático médio, mostraram que os modelos configurados com a função de pertinência trapezoidal apresentaram a menor taxa de erro contra um conjunto de 100 mil conexões aleatórias. No entanto, os três modelos testados se mostraram aptos a detectarem anomalias em conexões, com taxas próximas às atingidas pelo modelo mais eficiente, podendo também serem considerados.

Um sistema de inferência neuro-fuzzy adaptativo (ANFIS) foi aplicado para prever a relação ‘condições de trabalho vs acidentes de trabalho’ com base em dados reais de acidentes originados em estaleiros. Os tipos de acidentes foram relacionados à

Fatores de Gravidade (GF) e usados como valores de entrada para formar o modelo ANFIS. Várias funções de pertinência foram utilizadas para a formação dos controladores. Pôde-se concluir com base no erro médio para a predição de riscos de acidentes que, utilizando a função Gaussiana obtém-se uma maior predição quando comparadas as demais Funções utilizadas (FRAGIADAKIS, TSOUKALAS e PAPA ZOGLU, 2014).

Sun *et al.* (2015) avaliaram as predições dos coeficientes de desempenho (COP – *Coefficient of Performance*), usando as técnicas de redes neurais artificiais (RNA) e neuro-fuzzy (ANFIS), para uma bomba de calor convencional e um bomba de calor geométrica com parâmetros limitados. O método baseado no modelo de rede neural foi testado com diferentes neurônios na camada oculta e foram comparados os COPs gerados. Os modelos com cinco neurônios na camada oculta pareceu ser a melhor topologia para a predição da COP para ambas as bombas testadas. Quanto ao método ANFIS, este foi testado com diferentes funções de pertinências e seus resultados foram comparados entre si. Os pesquisadores observaram que para a bomba de calor, a função Gaussiana com três funções de pertinências foi a que apresentou melhor COP. Já o modelo ANFIS ideal para prever os COP da bomba de calor geométrica foi a Gaussiana com duas funções de pertinência. Constataram também que, os dois modelos testados apresentaram alta precisão e confiabilidade para calcular os índices de desempenhos dos sistemas estudados.

Em termos de requisitos de tempo real, ou seja, uso mínimo de memória e obtenção de cálculos mais rápidos, na literatura é possível encontrar recomendações para o uso da função de pertinência triangular, que está presente na forma padrão do sistema fuzzy. (FILETI, ANTUNES, *et al.*, 2007).

Pelos relatos da literatura, observa-se que chegar na configuração ideal do controlador não é uma tarefa simples, porém é essencial para alcançar a precisão da resposta pretendida. Nota-se também que a literatura tem focado sua atenção nas regras que mais se destacam dentro do conjunto gerado, ou seja, nas funções de pertinência e também que, estudos relacionado a processos químicos pouco são explorados quanto aos efeitos que tais configurações de controle podem proporcionar. Sendo assim, pretende-se fazer uma avaliação mais ampla, considerando as etapas de fuzificação,

inferência e defuzificação e, compreender os efeitos gerados por estes ajustes em processos químicos.

Capítulo 3

Simulação Computacional

O presente Capítulo tem como propósito apresentar: (i) o processo de neutralização; (ii) a elaboração da base de conhecimento do sistema neuro-fuzzy; (iii) a simulação das diferentes configurações do controlador neuro-fuzzy. Todas estas etapas foram realizadas através das ferramentas computacionais *InduSoft Web Studio*[®] (IWS) e *Matlab*[®].

As simulações e os modelos apresentados nesse Capítulo (planta do processo, conhecimento especialista e os controladores formados) serão utilizados para o entendimento dos efeitos que as configurações dos controladores ANFIS oferecem sobre a resposta de controle do sistema proposto.

3.1 Processo de neutralização do pH

A planta em estudo é formada por um reator de tanque contínuo agitado (CSTR) alimentado por duas correntes: uma corrente de solução ácida (HCl) e uma corrente de solução básica (NH₄OH). A concentração dos reagentes são $1,86 \cdot 10^{-3}$ kmol/m³ de ácido e $1,00 \cdot 10^2$ kmol/m³ de base. O estado de equilíbrio do processo ocorre quando as concentrações dos íons hidrogênio e hidroxila forem equivalentes. A vazão

nominal do ácido no regime estacionário (F_a), bem como a vazão de base (F_b) são iguais a $0,264 \text{ m}^3/\text{min}$ e $0,236 \text{ m}^3/\text{min}$ respectivamente e, correspondem ao valor de pH de 10. Nesse processo, o ácido de clorídrico (HCl) deve ser continuamente neutralizado por hidróxido de amônio (NH_4OH). O nível do tanque pode ser ajustado por uma válvula localizada na saída do tanque de mistura com limites entre 0% (fechada) e 100% (aberta). Um controlador neuro-fuzzy é empregado para ajustar o perfil da variável manipulada assegurando os valores de pH desejado e um outro controlador neuro-fuzzy é utilizado no controle da vazão de saída para manutenção do nível do meio reacional.

Para este processo, assume-se que a mistura é instantânea. A temperatura do meio e a densidade da mistura são constantes. Um esquema simplificado do processo de neutralização é descrito na Figura 3. As especificações físicas do reator encontram-se na Tabela 2. As variáveis do processo em conjunto com seus valores nominais são apresentadas na Tabela 3.




Figura 3: Diagrama do processo de neutralização em estudo.

Tabela 2: Especificação do reator.

Variáveis	Símbolo	Parâmetros
Altura	h	$2,500 \text{ m}$
Área da base	A_b	$4,909 \text{ m}^2$
Volume	V_r	$9,818 \text{ m}^3$

Tabela 3: Valores nominais das variáveis de processo.

Variáveis	Símbolo	Valores Nominais
Vazão do ácido (linha 1)	$F_a (F_{HCl})$	0,264 m ³ /min
Vazão da base (linha 2)	$F_b (F_{NH_4OH})$	0,236 m ³ /min
Vazão de saída	$F_s (F_{saida})$	0,500 m ³ /min
Concentração do ácido	[HCl]	1,00.10 ² kmol /m ³
Concentração da base	[NH ₄ OH]	1,86.10 ⁻³ kmol /m ³
Potencial Hidrogeniônico	pH	10,00
Altura Reacional (nível)	L	2,00 m

3.1.2 Modelo matemático do processo de neutralização

A modelagem matemática do reator de neutralização estudado foi baseada numa planta didática de neutralização onde, utiliza-se a hipótese de mistura perfeita e dos invariantes reacionais, isto é os parâmetros não são distribuídos no reator e os compostos são inertes perante a reação. O modelo dinâmico utilizado nesta simulação constitui em um conjunto de equações diferenciais não-lineares de primeira ordem. O balanço de massa no reator utilizando-se das hipóteses anteriormente citadas encontra-se representado nas Equações 8, 9 e 10 e descrevem o comportamento dinâmico do processo.

$$\frac{d[HCl] \cdot V}{dt} = F_{HCl} \cdot [HCl]_{entra} - F_s[HCl] \quad (8)$$

$$\frac{d[NH_4OH] \cdot V}{dt} = F_{NH_4OH} \cdot [NH_4OH]_{entra} - F_s[NH_4OH] \quad (9)$$

$$\frac{dV}{dt} = F_{HCl} + F_{NH_4OH} - F_s \quad (10)$$

Considerando-se a área da seção transversal do reator (A_b) constante e a atuação sendo realizada por uma válvula de saída, obtêm-se as Equações 11, 12 e 13.

$$A_b \frac{dh}{dt} = F_{HCl} + F_{NH_4OH} + c_v \cdot a_v \sqrt{h} \quad (11)$$

$$\frac{d[HCl]}{dt} = \frac{F_{HCl} \cdot [HCl]_{entra}}{h \cdot A_b} - \left(c_v \cdot a_v \sqrt{h} + A_b \frac{dh}{dt} \right) \cdot \frac{[HCl]}{h \cdot A_b} \quad (12)$$

$$\frac{d[NH_4OH]}{dt} = \frac{F_{NaOH} \cdot [NH_4OH]_{entra}}{h \cdot A_b} - \left(c_v \cdot a_v \sqrt{h} + A_b \frac{dh}{dt} \right) \cdot \frac{[NH_4OH]}{h \cdot A_b} \quad (13)$$

O cálculo do pH é fornecido diretamente pelo balanço de cargas de acordo com a Equação 14, considerando que o ácido e a base do sistema dissociam-se completamente, que o processo ocorre à temperatura ambiente e esta não varia significativamente durante o estudo.

$$[HCl] \cdot (-1) + [NH_4OH] \cdot (+1) + 10^{-pH} - 10^{pH-14} = 0 \quad (14)$$

3.2 Base de conhecimento especialista

Na intenção de apresentar um método alternativo prático para a geração da base de dados utilizando o conhecimento especialista, foi desenvolvido um sistema supervisório virtual não imersivo, integrando simulação fenomenológica dinâmica programada em *Matlab®/Simulink* e sistema de supervisão industrial projetada em *InduSoft Web Studio®* (IWS). Este sistema permitiu construir, em tempo real, uma base de dados usando controle manual em uma planta virtual e, ainda, forneceu ao usuário um ambiente prático, de rápida visualização dos elementos básicos de um processo industrial em termos de aparência, comportamento, funcionalidades e operação.

Com base no processo de neutralização do pH descrito no item 3.1, os dados para treinamento do controlador foram gerados partindo-se do processo nas condições de regime permanente e realizando freqüentes alterações na vazão de HCl (distúrbio) e manipula-se a corrente de NH₄OH (manipulada) até alcançar um novo regime permanente. As dinâmicas das válvulas utilizadas para as vazões de entrada e saída do processo foram representadas pelo manuseio operacional do sistema supervisório virtual desenvolvido. Com os ajustes manuais realizados em tempo real nas duas variáveis manipuladas, assegurou-se que os valores de pH e nível do tanque estão nas condições

desejadas para o processo, frente as várias perturbações geradas no processo no domínio do tempo.

Um banco de dados é então formado, contendo as estimativas dos erros para cada estrutura criada, através do controle manual do processo representado pela tela de comando do sistema supervisorio desenvolvido. Buscou-se formar um banco de dados suficiente para utilizar o método de validação cruzada, ou seja, uma parte dos dados foi disponibilizada para treinamento da rede ANFIS e outra parte para checar e validar o treinamento da rede.

3.2.1 Sistema Supervisorio - *InduSoft Web Studio*[®] (IWS)

Um sistema supervisorio, basicamente, destina-se a capturar e armazenar em um banco de dados, as informações sobre um processo de produção. Para as aplicações industriais, as informações vêm de sensores que detectam dados específicos (conhecidos como variáveis de processo) da planta industrial. Porém, em se tratando de simulação computacional, as informações são fornecidas de outro software capaz de realizar simulações numéricas. Sendo assim, para construir uma base de dados partindo de uma planta virtual faz-se necessária a criação de uma tela de comandos (interface) para propiciar a interação entre o usuário e o sistema. Nesta interface usuário/sistema, o operador envia as informações ao modelo de simulação e monitora as variáveis da planta em tempo real.

Atualmente, há vários softwares destinados a supervisionar processos promovendo a interface homem/máquina com telas devidamente configuradas e/ou animadas em função das informações recebidas. O software empregado neste estudo foi o *InduSoft Web Studio*[®](IWS) cuja a tela de comando foi criada a partir de uma biblioteca de gráficos de equipamentos, tubulações e instrumentos, disponível no próprio programa. A tela foi projetada priorizando o conceito de funcionalidade na operação manual e a facilidade de visualização das variáveis do processo. Uma atenção especial foi dada os gráficos de vazão, pH e nível do tanque permitindo a monitoração e manuseio das variáveis, em tempo real.

O novo ambiente virtual criado no IWS atua, neste estudo, como uma espécie de sistema intermediário, ou seja, o sistema supervisor *Indusoft* recebe as informações do processo elaborado no *Matlab*[®]/*Simulink*, permite a manipulação virtual das variáveis manipuladas e reenvia os dados manipulados ao simulador *Matlab*[®]/*Simulink* para nova simulação. Durante a simulação, todas as informações geradas são armazenadas em planilhas eletrônicas, formando a base de dados do sistema em estudo.

3.2.2 Sistema de Comunicação

A comunicação do sistema supervisor com o programa *Matlab*[®]/*Simulink* foi estabelecida via protocolo OPC (*Ole for Process Control*) possibilitando assim, a integração entre os dois sistemas propostos. Para isso, foi necessário inserir dois blocos no ambiente *Simulink* denominados: (i) OPC (*Block parameters: OPC Configuration*) e (ii) OPC (*Client Manager*) já existente no *Matlab*[®]/*Simulink* e configurar ambos os sistemas (*Matlab*[®]/*Simulink* e IWS) para enviar e receber as informações do processo, em tempo real.

As variáveis de entradas configuradas no bloco “OPC Write” no *Matlab*[®]/*Simulink* foram: pH, nível, vazão de ácido, vazão de base e abertura da válvula. As configurações para o sincronismo e tempo foram, *asynchronous* e 1 (um) segundo. Como variáveis de saídas para o OPC foi considerada o desvio da vazão de base e abertura da válvula. Para o IWS foram escolhidas as configurações do drive OPC UA através da criação de um servidor com as variáveis de entrada e saída do sistema. Neste caso, foi considerado 1000 ms e sistema servidor OPC.

Durante o *run time*, as informações de entrada provenientes do *Matlab*[®]/*Simulink* são enviadas ao servidor OPC e apresentadas na tela de comandos do IWS. As alterações realizadas na tela do IWS são enviadas então, em tempo real, para o ambiente no *Matlab*[®]/*Simulink*.

O protocolo OPC é capaz de formar e registrar banco de dados em tempo real. Para isso, é necessário configurar o software para enviar todas as informações gerenciadas pela tela de supervisão para o sistema *Matlab*[®]/*Simulink* através do bloco OPC Read.

3.3 Simulação das configurações ANFIS

3.3.1 Estrutura de entrada do controlador ANFIS

Para a formação da estrutura de entrada dos controladores neuro-fuzzy, utilizou-se do erro entre a medição do processo e o *set-point* e da diferença entre o erro do instante amostrado e seu antecessor ($\Delta e(k)$) para ambos os sistemas de nível e pH ao invés da derivada do erro no tempo. Optou-se pela diferença entre erros como uma alternativa à derivada do erro, pois a simulação com esta última tornava o sistema demasiadamente rígido, mesmo após alterar as tolerâncias numéricas ou os algoritmos para resolução das equações diferenciais no Matlab®/Simulink. Esta alternativa foi baseada nos resultados apresentado por Garrido *et al.* (1997) e Adroer *et al.* (1999).

Valores para o erro $e(k)$ e sua diferença $\Delta e(k)$, que ocorrem durante o funcionamento do sistema ANFIS, formam então as entradas do sistema. Estas entradas são definidas nas Equações 15 e 16.

$$e(k) = E(k) - S(k) \quad (15)$$

$$\Delta e(k) = e(k) - e(k-1) \quad (16)$$

onde $E(k)$ e $S(k)$ correspondem a: entrada (E) de referência, saída (S) real do sistema e tempo de amostragem (k), respectivamente.

Tabela 4: Configurações do bloco ANFIS.

Tipo de Função de Pertinência	Método 'e'	Método 'ou'	Tipo de saída da Função de Pertinência	Método de Otimização
triangular	produto	probabilístico	constante	híbrido

Sendo assim, para determinar a estrutura ideal para a rede neuro-fuzzy com base no conhecimento especialista criado, usou-se do procedimento a seguir. Partiu-se então, da configuração padrão do controlador ANFIS apresentado na Tabela 4, alterando apenas a variação do erro no tempo: (k_i) , (k_i-1) , (k_i-2) , para as entradas e saída do controlador. Inicia-se, então, com cinco entradas sendo: $E_1(k_e)$, $E_2(k_e-1)$, $E_3(k_{Ac})$, $E_4(k_{Ac}-1)$, $E_5(k_{Bs}-1)$ e $S(k_{Bs})$ e aumenta-se gradualmente o número de variações no tempo (entradas da rede) até que o acréscimo de novas variáveis de entrada apresente

sobrecarga de esforço computacional, proporcionando lentidão do processamento e problemas de consumo exagerado de memória devido o aumento exponencial das camadas internas da rede neural.

Tabela 5: Estrutura de entrada do controlador neuro-fuzzy - pH.

Nr. da estrutura	Entradas da rede ANFIS	Nr. total de entrada
1	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Bs}-1) \& S(k_{Bs})$	5
2	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Bs}-1), E_6(k_{Bs}-2) \& S(k_{Bs})$	6
3	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(k_{Bs}-1) \& S(k_{Bs})$	6
4	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Bs}-1) \& S(k_{Bs})$	6
5	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(k_{Bs}-1), E_7(k_{Bs}-2) \& S(k_{Bs})$	7
6	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Bs}-1), E_7(k_{Bs}-2) \& S(k_{Bs})$	7
7	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(k_{Bs}-1), \& S(k_{Bs})$	7
8	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(k_{Bs}-1), E_8(k_{Bs}-2) \& S(k_{Bs})$	8

Tabela 6: Estrutura de entrada do controlador neuro-fuzzy - nível do tanque.

Nr. da estrutura	Entradas da rede ANFIS	Nr. total de entrada
1	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(K_{Av}-1) \& S(K_{Av})$	5
2	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(K_{Av}-1), E_6(K_{Av}-2) \& S(K_{Av})$	6
3	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(K_{Av}-1) \& S(K_{Av})$	6
4	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(K_{Av}-1) \& S(K_{Av})$	6
5	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(K_{Av}-1), E_7(K_{Av}-2) \& S(K_{Av})$	7
6	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(K_{Av}-1), E_7(K_{Av}-2) \& S(K_{Av})$	7
7	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(K_{Av}-1), \& S(K_{Av})$	7
8	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(K_{Av}-1), E_8(K_{Av}-2) \& S(K_{Av})$	8

A determinação da melhor estrutura para os controladores ANFIS foi baseada no erro quadrático médio (EQM) apresentado pela Equação 17.

$$EQM = \sum_{t=1}^n \frac{(x-x^*)^2}{n} \quad (17)$$

onde, x^* representa o valor da previsão de controle (saída real) e x o valor deseja do utilizado no treinamento ANFIS.

O cálculo (EQM) permite conhecer qual a é previsão de desempenho do controlador quanto ao seu valor de referência informado, facilitando a escolha do menor erro quadrático médio (EQM) alcançado pelo controlador durante as etapas de treinamento e testes.

3.3.2 Configuração da base de regras ANFIS

De acordo com Li e Gatland (1996), a configuração de controladores com base em regras fuzzy é difícil devido ao ajuste múltiplo simultâneo. Não há uma metodologia bem definida para a escolha das funções de pertinência e demais parâmetros existentes nesses controladores. Em termos de requisitos de tempo real (uso mínimo de memória e cálculos rápidos), é recomendado o uso de função de pertinência na forma triangular. Se o erro ou desempenho encontrado para a função de pertinência triangular não for satisfatória, recomenda-se que novas funções de pertinências sejam testadas, ou seja, o dimensionamento dos parâmetros são determinados a partir de procedimento de tentativa e erro com base em índices de desempenho, tais como erro quadrático médio, *ISE*, *IAE*, *ITAE* ou *ITSE*. Logo, compreender seus efeitos poderá poupar trabalho podendo-se optar por parâmetros que produzem maior significância quanto ao desempenho do modelo.

Para implementar o controlador neuro-fuzzy optou-se pelo uso da biblioteca de blocos pré-definidos do *Simulink*, que fornece o ferramental necessário para criar e editar sistemas de inferência fuzzy de maneira funcional e prática, como é o caso do bloco fuzzy utilizado neste estudo.

O bloco fuzzy do *Matlab*[®] possibilita ao usuário selecionar um dos métodos para utilização, ou seja, Mamdani ou Sugeno e, como já mencionado no item 2.1.3.4, dependendo do tipo selecionado, são liberados os campos pertinentes para a configuração das informações dos dados de entrada e dos demais ajustes. Isto é, para a opção de controlador de Sugeno, os campos referentes à função de implicação, ao termo de agregação e ao método de defuzzificação ficam desabilitados. O programa apresenta várias opções ao usuário para a configuração dos componentes do sistema e, para a maioria dos campos, também permite a definição de outras alternativas, porém, não é possível incluir regras próprias para as funções de pertinência e funções defuzzificação. Deve-se usar das configurações já fornecidas pela ferramenta para a formação das regras. As Figuras 4, 5, 6 e 7 representam as possibilidades de configurações a serem exploradas neste estudo.




Figura 4: Localização do método de inferência disponível no bloco ANFIS.




Figura 5: Localização do tipo de FP disponível no bloco ANFIS.




Figura 6: Localização do tipo de função de saída disponível no bloco ANFIS.




Figura 7: Localização do método de otimização disponível no bloco ANFIS.

Deve-se levar em conta também que no método Sugeno apenas uma saída é possível para cada treinamento, portanto ao invés de realizar o treinamento com uma estrutura contemplando as duas variáveis de saída pH e nível do tanque, como é possível para as redes neurais, foram realizadas duas estruturas, um para os valores do pH desejado e outro para a manutenção do nível da mistura no tanque.

A Tabela 7 resume o planejamento das configurações a serem selecionadas para cada tipo de função de pertinência (FP) adotada, ou seja, triangular (trimf), trapezoidal (trmf), gaussiana simétrica (gaussmf), gaussiana não simétrica (gauss2mf), sino (gbellmf), sigmoidal (sigmf), diferença entre duas funções sigmoidais (dsigmf), produto entre duas funções sigmoidais (psigmf), função spline Z (zmf), função spline S (smf), produto entre duas funções spline (pmf), já apresentadas no Capítulo 2. Com isso, o tipo de função de pertinência e, portanto, também parâmetros, tornaram-se organizadas para dispor de uma arquitetura que inclua todas as possibilidades significativas de arranjos de maneira sistemática e concisa. Vale mencionar aqui que, esta tabela se repete para cada tipo de função de pertinência avaliada. Com esta etapa concluída, as arquiteturas propostas podem ser testadas e seus erros analisados.

Tabela 7: Configuração das propostas para as regras do controlador ANFIS.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da Função de Pertinência	Método de Otimização
1	produto	probabilístico	linear	híbrido
2	mínimo	probabilístico	linear	híbrido
3	produto	máximo	linear	híbrido
4	mínimo	máximo	linear	híbrido
5	produto	probabilístico	constante	híbrido
6	mínimo	probabilístico	constante	híbrido
7	produto	máximo	constante	híbrido
8	mínimo	máximo	constante	híbrido
9	produto	probabilístico	linear	retropropagação
10	mínimo	probabilístico	linear	retropropagação
11	produto	máximo	linear	retropropagação
12	mínimo	máximo	linear	retropropagação
13	produto	probabilístico	constante	retropropagação
14	mínimo	probabilístico	constante	retropropagação
15	produto	máximo	constante	retropropagação
16	mínimo	máximo	constante	retropropagação

3.3.3 Desempenho do sistema de controle

Para avaliar o desempenho do sistema de controle proposto foram utilizados critérios de desempenho baseados na evolução do erro no tempo. Os critérios de desempenho *Integral of the Square Error (ISE)*, *Integral of the Absolute Value of the Error (IAE)*, *Integral of the time-weighted absolute error (ITAE)* e *Integral of the Square Error (ITSE)*, representados na Tabela 8, auxiliam na verificação da melhor estrutura de controle e, conseqüentemente, no melhor conjunto de regras para o controlador.

Os critérios de desempenho *ISE*, *IAE*, *ITAE* e *ITSE* auxiliam na sintonia de controladores ao fornecerem dados que permitem inferir o quão eficiente o sistema de controle foi ao tentar manter a variável de processo em seu valor de *set-point* (STEPHANOPOULOS, 1984). O critério *ISE* e *ITSE* permitem melhor identificar erros grandes pois eleva seu valor ao quadrado, sendo que, o critério *IAE* identifica os erros de valores menores, enquanto *ITAE* possibilita identificar erros que persistem no tempo.

Tabela 8: Critérios de Desempenho *IAE*, *ISE*, *ITAE* e *ITSE*.

<i>Integral of the Absolute Value of the Error</i>	$IAE = \int_{t_0}^t e(t) dt$
<i>Integral of the Square Error</i>	$ISE = \int_{t_0}^t e(t) ^2 dt$
<i>Integral of the Time-Weighted Absolute Error</i>	$ITAE = \int_{t_0}^t t \cdot e(t) dt$
<i>Integral of the Square Error</i>	$ITSE = \int_{t_0}^t t e^2(t) dt$

Capítulo 4

Resultados e Discussões

4.1 Processo de neutralização do pH

Conforme descrito no item 3.1, o modelo de controle da planta foi realizado em ambiente *Matlab®/Simulink*. A implementação do modelo fenomenológico em malha aberta para aquisição do conhecimento especialista, a implementação dos controladores ANFIS para a escolha da arquitetura com posterior análise dos conjuntos de parâmetros e seus desempenhos no processo foram feitas separadamente para análise das estratégias de controle. A Figura 8 apresenta a tela principal elaborada para esta simulação e o bloco de nome ‘Processo de Neutralização’ é detalhado na Figura 9. Neste último bloco estão implementadas as Equações 8 a 14 apresentadas no Capítulo 3 e considerando os parâmetros apresentados nas Tabelas 2 e 3 deste mesmo capítulo.

Após a implementação do modelo matemático do processo, foi possível avaliar a resposta dinâmica do processo em malha aberta e, para tal, optou-se pelo método implícito de *Runge-Kutta* (23tb/TR-BDF2) e manteve-se o passo de integração numérica no padrão disponível pelo *Simulink* para solução das equações diferenciais do modelo matemático desenvolvido. Na sequência, ajustou-se o processo para as condições de estado estacionário com o auxílio da curva de titulação do processo que foi gerada mantendo a vazão de NH_4OH constante e variando gradativamente a vazão de HCl .




Figura 8: Modelado processo de neutralização implementado no Matlab®/Simulink com interface de comunicação (OPC) para o Indusoft (IWS).




Figura 9: Modelo matemático do processo implementado no Matlab®/Simulink.

Para determinar o tempo de estabilização da reação, criou-se uma perturbação degrau do pH 7 (neutro) para o pH 10 e observou-se quanto tempo foi necessário para alcançar a condição de regime permanente para a nova condição estabelecida. Na Figura 10 e 11 pode ser verificado que o tempo para alcançar a estabilização da reação para a variável controlada pH foi de aproximadamente 110s e 270s para a variável controlada nível do tanque, com isso, determinou-se que intervalos de 300s para cada perturbação realizadas no processo seriam necessárias para estabilizar as duas variáveis manipuladas, pH e nível do tanque, usando ajuste manual. Os valores encontrados no estado estacionário foram 0,264 kmol/m³ para a vazão de NH₄OH e 0,236 kmol/m³ para a vazão de HCl com pH 10 e 2 metros de nível do tanque.




Figura 10: Resposta dinâmica do processo em malha aberta para a variável controlada pH.




Figura 11: Resposta dinâmica do processo em malha aberta para a variável controlada Nível do tanque.

Três subsistemas também foram criados com o intuito de armazenar o banco de dados do processo e suas várias estruturas necessárias para o treinamento do controlador ANFIS.

Com as condições do estado estacionário do processo estabelecida, iniciou-se a configuração da interface entre o modelo matemático implementado no *Simulink* com o sistema supervisorio. A Figura 12 apresenta o bloco de interface OPC utilizado para comunicação entre a simulação implementada no *Matlab*® e o sistema supervisorio. No módulo OPC, foi necessário carregar as informações enviadas ao supervisorio do processo (*OPC write*) tais como, F_{HCl} , F_{NH4OH} e Abertura da válvula (A_v) e as informações recebidas pelo processo manipulado (*OPC read*) tais como, $desvb$ e $desvv$ para que o sistema de comunicação fosse estabelecido. Estando configurado o módulo OPC no *Matlab*®, pôde-se então preparar a tela de supervisão para a manipulação do processo de neutralização e formação do banco de dados do conhecimento especialista.




Figura 12: Interface de comunicação do processo implementado no Matlab®/Simulink com o sistema supervisorio construído na plataforma Indusoft.

4.2 Sistema de supervisão Virtual

A idealização de se usar este sistema virtual de supervisão industrial como gerador de dados para o treinamento dos controladores veio da possibilidade de se imitar o controle manual realizado pelo especialista do processo e representa as informações

presentes numa planta física real de neutralização. Ressalta-se que, o Sistema de Supervisão Industrial (SVI) criado ao receber a comunicação com o ambiente *Matlab®/Simulink* atuou como sistema intermediário.

Sendo assim, foi criada uma tela de comandos virtuais no *software InduSoft Web Studio (IWS)*, priorizando o conceito de funcionalidade da operação. A facilidade de visualização da planta de forma realística possibilitou a manipulação de dados virtualmente e o recolhimento das informações do processo em um banco de dados do tipo ‘planilha eletrônica’.

Na Figura 13 é ilustrada a tela de comando do IWS elaborada para esta simulação. Para o sistema de supervisão industrial citado, verificou-se que os ajustes manuais realizados para as duas variáveis manipuladas foram capazes de corrigir as variáveis controladas até seu valor de *set-point* e representou de forma satisfatória a dinâmica do processo para as todas as perturbações geradas no domínio do tempo.




Figura 13: Tela (SVI) elaborado em *InduSoft Web Studio (IWS)*.

Portanto, fazendo uso de perturbações no processo, foi simulado o controle virtual do modelo em malha aberta, incluídos os ruídos pertinentes ao processo. A duração de cada período de atuação operacional sobre a planta foi de 60 minutos com amostras de um segundo, formando um conjunto de dados com 3600 amostras. Os

conjuntos de dados de entrada e saída do processo estão apresentados nas Figuras 15 a 18 e foram utilizados para o treinamento da rede neuro-fuzzy.

Devido a reação envolvida neste processo de neutralização ser composta por um ácido forte e uma base fraca, a neutralização somente torna-se possível para pequenas faixas de variações na corrente de solução ácida. Com isso, os distúrbios provocados na vazão de HCl permaneceram entre 0,350 m³/min a 0,150 m³/min tornando possível o processo de neutralização proposto. A seqüência destes valores, considerando desvios em toda a faixa de variação, podem ser verificados na Figura 14.




Figura 14: Seqüência de perturbações realizadas na vazão de HCl do processo de neutralização.




Figura 15: Ajustes manuais realizados na vazão de NH₄OH durante o controle regulatório do processo.




Figura 16: Abertura da válvula de saída do tanque para controle do nível.




Figura 17: Controle regulatório, em malha aberta, para a variável controlada pH.




Figura 18: Controle regulatório, em malha aberta, para a variável controlada nível do tanque.

Como resultado final para o SVI desenvolvido notou-se que, esta propiciou ilustrar todos os parâmetros necessários ao controle da planta química, foi capaz de processar todas as alterações realizadas pelo especialista e gerar um banco de dados de linguagem simples. Parâmetros de processo, tais como, os valores das variáveis no tempo, as indicações dos acionamentos das bombas, as porcentagem de abertura de válvulas, as entradas de *set-point* para as variáveis de controle pH e o nível do tanque de neutralização foram facilmente localizadas e os ajustes das variáveis realizados sem dificuldades.

4.3 Estrutura de entrada do controlador ANFIS

Para a determinação da estrutura ideal para a rede neuro-fuzzy com base no conhecimento especialista criado, foram simuladas as 8 estruturas de controle propostas seguindo a metodologia exposta nos itens 3.3.1 e 3.3.2. Para todas as simulações a base de regra foi a mesma (conforme Tabela 4), ou seja, foram mantidas fixas as configurações iniciais do padrão presente no bloco ANFIS do Matlab®/Simulink e alterado somente o conjunto de dados da entrada do controlador. As tabelas 9 e 10 apresentam os resultados obtidos para as 8 estruturas avaliadas.

Durante o aprendizado do controlador ANFIS, utilizou-se tolerância de 10^{-3} , 100 épocas de treinamento e método da validação cruzada para os dados do treinamento e validação. O número de épocas de treinamento foi estabelecido observando que não ocorria melhoria significativa após um determinado número de épocas.

Com base nos resultados de treinamento da Tabela 9, a estrutura 5 com sete entradas foi a escolhida para a variável pH e a estrutura 4 com seis entradas foi a escolhida para a variável nível do tanque contendo os menores erros de treinamento e portanto, considerada como sendo o melhor conjunto de entrada para cada variável de saída do processo. O conjunto de entrada para o controlador da variável pH foi: $E_1(k_e)$, $E_2(k_e-1)$, $E_3(k_{Ac})$, $E_4(k_{Ac}-1)$, $E_5(k_{Ac}-2)$, $E_6(k_{Bs}-1)$, $E_7(k_{Bs}-2)$ & $S(k_{Bs})$ e para a variável nível do tanque o conjunto de entrada escolhido foi: $E_1(k_e)$, $E_2(k_e-1)$, $E_3(k_e-2)$, $E_4(k_{Ac})$, $E_5(k_{Ac}-1)$, $E_6(K_{Av}-1)$ & $S(K_{Av})$.

Tabela 9: Influência da entrada na estrutura do controlador neuro-fuzzy- variável pH.

Estruturas	Configuração de entrada da rede ANFIS	Σ Entrada	(EQM)		
			Treino	Teste	Validação
1	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Bs}-1) \text{ \& } S(k_{Bs})$	5	7,230E-02	1,587E-02	9,667E-03
2	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Bs}-1), E_6(k_{Bs}-2) \text{ \& } S(k_{Bs})$	6	6,351E-02	2,027E-02	8,570E-03
3	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(k_{Bs}-1) \text{ \& } S(k_{Bs})$	6	7,000E-02	1,296E-02	8,165E-03
4	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Bs}-1) \text{ \& } S(k_{Bs})$	6	6,926E-03	2,112E-02	8,544E-03
5	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(k_{Bs}-1), E_7(k_{Bs}-2) \text{ \& } S(k_{Bs})$	7	6,052E-03	6,007E-03	2,805E-03
6	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Bs}-1), E_7(k_{Bs}-2) \text{ \& } S(k_{Bs})$	7	6,339E-03	9,955E-03	4,648E-03
7	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(k_{Bs}-1), \text{ \& } S(k_{Bs})$	7	7,148E-03	1,242E-02	1,712E-03
8	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(k_{Bs}-1), E_8(k_{Bs}-2) \text{ \& } S(k_{Bs})$	8	6,164E-02	1,382E-02	2,748E-03

Tabela 10: Influência da entrada na estrutura do controlador neuro-fuzzy - variável nível.

Estruturas	Configuração de entrada da rede ANFIS	Σ Entrada	(EQM)		
			Treino	Teste	Validação
1	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(K_{Av}-1) \text{ \& } S(K_{Av})$	5	7,194E-03	2,882E-01	1,729E-03
2	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(K_{Av}-1), E_6(K_{Av}-2) \text{ \& } S(K_{Av})$	6	6,884E-03	1,947E-01	2,392E-02
3	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(K_{Av}-1) \text{ \& } S(K_{Av})$	6	7,186E-03	1,575E-01	9,739E-03
4	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(K_{Av}-1) \text{ \& } S(K_{Av})$	6	6,470E-03	1,002E-01	2,046E-02
5	$E_1(k_e), E_2(k_e-1), E_3(k_{Ac}), E_4(k_{Ac}-1), E_5(k_{Ac}-2), E_6(K_{Av}-1), E_7(K_{Av}-2) \text{ \& } S(K_{Av})$	7	7,210E-03	1,843E-01	2,843E-02
6	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(K_{Av}-1), E_7(K_{Av}-2) \text{ \& } S(K_{Av})$	7	6,867E-03	1,118E-01	9,419E-03
7	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(K_{Av}-1), \text{ \& } S(K_{Av})$	7	7,169E-02	2,092E-01	7,774E-02
8	$E_1(k_e), E_2(k_e-1), E_3(k_e-2), E_4(k_{Ac}), E_5(k_{Ac}-1), E_6(k_{Ac}-2), E_7(K_{Av}-1), E_8(K_{Av}-2) \text{ \& } S(K_{Av})$	8	6,630E-02	1,865E-01	7,661E-02

4.4 Configuração da Base de regras ANFIS

Considerando a estrutura ideal escolhida para o controlador neuro-fuzzy para ambas as variáveis controladas, foram simuladas as 16 diferentes propostas de configuração para cada função de pertinência do controlador ANFIS, conforme descrito na Tabela 7 do item 3.3.2 e os resultados dos erros quadrados médios (EQM) foram comparados entre si.

Nas Tabelas 11 e 12, são apresentados os resultados relativos aos conjuntos de configurações que apresentaram o menor erro de treinamento dentre as funções de pertinências avaliadas.

Observou-se então que, as funções Gaussiana Simétrica, Gaussiana não Simétrica e Triangular apresentaram EQM de treinamento menor que 10^{-3} para a variável pH e que o mesmo não se observa pra a variável Nível do tanque que não obteve nenhuma função com erro inferior ao erro especificado ao controle fuzzy proposto. De maneira geral, ambas as variáveis não mostraram altas variações quanto a taxa do erro. Esse comportamento também foi observado no trabalho de Nunes e Ribeiro (2003) que, apesar dos resultados encontrados mostrarem uma menor taxa de erro para uma das funções de pertinência testada, todos os modelos avaliados apresentaram-se aptos para aplicação.

Entretanto, os resultados das simulações adotando a função Gaussiana Simétrica foram as que mais se destacaram apresentando a menor taxa de erro para as duas variáveis controladas evidenciando que a escolha da função de pertinência detém forte influencia sobre as demais configurações adotadas dentro do conjunto de parâmetros do controlador, o que já era esperado, uma vez que é a função de pertinência que associa cada elemento do conjunto a um grau de pertinência do mesmo, conforme mencionado no item 2.1.3.3.

Para todos os ensaios realizados, nenhum apresentou a saída da função de pertinência tipo constante como favorável ao desempenho do controlador. Notou-se também uma piora no desempenho quando o método de otimização foi baseado no algoritmo de retropropagação.

Tabela 11: Menor erro de treinamento entre as funções avaliadas- variável pH.

Nr. do Ensaio	Função de Pertinência	Método ‘e’	Método ‘ou’	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
						Treino	Teste
2	triangular	mínimo	probor	linear	híbrido	2,44E-04	7,72E-03
17	trapezoidal	produto	probor	linear	híbrido	3,37E-02	4,59E-02
33	sino	produto	probor	linear	híbrido	1,86E-03	6,11E-03
49	gauss.sim.	produto	probor	linear	híbrido	1,03E-04	1,11E-03
65	gauss2.sim.	produto	probor	linear	híbrido	3,00E-04	6,72E-03
81	sigmoidal	produto	probor	linear	híbrido	1,96E-03	1,44E-02
97	dif. sigmoidal	produto	probor	linear	híbrido	5,60E-03	4,36E-02
113	prod.sigmoidal	produto	probor	linear	híbrido	3,59E-03	7,00E-02
130	função p	mínimo	probor	linear	híbrido	6,50E-03	4,87E-02
-	função s	produto	probor	linear	híbrido	N/A	N/A
-	função z	produto	probor	linear	híbrido	N/A	N/A

Tabela 12: Menor erro de treinamento entre as funções avaliadas – variável nível do tanque.

Nr. do Ensaio	Função de Pertinência	Método ‘e’	Método ‘ou’	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
						Treino	Teste
1	triangular	produto	probor	linear	híbrido	2,88E-02	1,21E-01
18	trapezoidal	mínimo	probor	linear	híbrido	5,85E-02	4,24E-01
33	sino	produto	probor	linear	híbrido	3,23E-02	1,02E-02
49	gauss. sim.	produto	probor	linear	híbrido	2,33E-02	1,80E-02
65	gauss2.sim.	produto	probor	linear	híbrido	3,93E-02	1,38E-02
81	sigmoidal	produto	probor	linear	híbrido	6,87E-02	1,16E-02
97	dif. sigmoidal	produto	probor	linear	híbrido	6,70E-02	2,66E-02
113	prod.sigmoidal	produto	probor	linear	híbrido	6,70E-02	2,66E-02
130	função p	mínimo	probor	linear	híbrido	5,92E-03	6,64E-02
-	função s	produto	probor	linear	híbrido	N/A	N/A
-	função z	produto	probor	linear	híbrido	N/A	N/A

Na seqüência, são apresentados os resultados encontrados para todos os controladores testados. Para a variável pH, os erros de treinamento são mostrados nas Tabelas 13 a 21 e nas Tabelas 22 a 30 são encontrados os erros para a variável Nível do tanque.

Tabela 13: Resultados dos treinamentos para a variável pH e Função Triangular.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
1	produto	probabilístico	linear	híbrido	5,88E-04	6,66E-02
2	mínimo	probabilístico	linear	híbrido	2,44E-04	7,72E-03
3	produto	máximo	linear	híbrido	5,88E-04	6,66E-02
4	mínimo	máximo	linear	híbrido	2,44E-04	7,72E-03
5	produto	probabilístico	constante	híbrido	6,05E-03	2,80E-03
6	mínimo	probabilístico	constante	híbrido	3,72E-02	6,52E-01
7	produto	máximo	constante	híbrido	6,87E-03	5,77E-02
8	mínimo	máximo	constante	híbrido	3,72E-02	6,52E-01
9	produto	probabilístico	linear	retropropagação	1,79E-02	4,98E-02
10	mínimo	probabilístico	linear	retropropagação	1,99E-02	4,63E-02
11	produto	máximo	linear	retropropagação	1,79E-02	4,98E-02
12	mínimo	máximo	linear	retropropagação	1,99E-02	4,63E-02
13	produto	probabilístico	constante	retropropagação	1,63E-02	4,61E-02
14	mínimo	probabilístico	constante	retropropagação	1,54E-02	5,98E-02
15	produto	máximo	constante	retropropagação	1,63E-02	4,61E-02
16	mínimo	máximo	constante	retropropagação	2,25E-02	5,06E-02

Tabela 14: Resultados dos treinamentos para a variável pH e Função Trapezoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
17	produto	probabilístico	linear	híbrido	3,37E-02	4,59E-02
18	mínimo	probabilístico	linear	híbrido	4,45E-02	5,11E-02
19	produto	máximo	linear	híbrido	3,37E-02	4,59E-02
20	mínimo	máximo	linear	híbrido	4,45E-02	5,11E-02
21	produto	probabilístico	constante	híbrido	3,41E-02	4,81E-02
22	mínimo	probabilístico	constante	híbrido	6,31E-02	8,09E-02
23	produto	máximo	constante	híbrido	6,95E-02	4,80E-02
24	mínimo	máximo	constante	híbrido	6,13E-02	8,09E-02
25	produto	probabilístico	linear	retropropagação	7,61E-02	6,30E-02
26	mínimo	probabilístico	linear	retropropagação	6,50E-02	7,40E-02
27	produto	máximo	linear	retropropagação	8,39E-02	6,51E-02
28	mínimo	máximo	linear	retropropagação	6,64E-02	7,68E-02
29	produto	probabilístico	constante	retropropagação	7,46E-02	9,29E-02
30	mínimo	probabilístico	constante	retropropagação	7,64E-02	8,82E-02
31	produto	máximo	constante	retropropagação	7,84E-02	9,31E-02
32	mínimo	máximo	constante	retropropagação	7,44E-02	8,82E-02

Tabela 15: Resultados dos treinamentos para a variável pH e Função Sino.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
33	produto	probabilístico	linear	híbrido	1,86E-03	6,11E-03
34	mínimo	probabilístico	linear	híbrido	7,28E-03	1,10E-02
35	produto	máximo	linear	híbrido	6,86E-03	1,88E-02
36	mínimo	máximo	linear	híbrido	7,28E-03	1,10E-02
37	produto	probabilístico	constante	híbrido	2,01E-02	4,31E-02
38	mínimo	probabilístico	constante	híbrido	2,59E-02	6,19E-02
39	produto	máximo	constante	híbrido	2,01E-02	4,31E-02
40	mínimo	máximo	constante	híbrido	2,68E-02	6,44E-02
41	produto	probabilístico	linear	retropropagação	1,12E-02	1,90E-02
42	mínimo	probabilístico	linear	retropropagação	1,09E-02	1,49E-02
43	produto	máximo	linear	retropropagação	1,12E-02	1,90E-02
44	mínimo	máximo	linear	retropropagação	1,09E-02	1,49E-02
45	produto	probabilístico	constante	retropropagação	1,83E-02	4,88E-02
46	mínimo	probabilístico	constante	retropropagação	1,84E-02	4,81E-02
47	produto	máximo	constante	retropropagação	1,84E-02	4,62E-02
48	mínimo	máximo	constante	retropropagação	1,55E-02	4,80E-02

Tabela 16: Resultados dos treinamentos para a variável pH e Função Gaussiana.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
49	produto	probabilístico	linear	híbrido	1,03E-04	1,11E-03
50	mínimo	probabilístico	linear	híbrido	7,05E-03	9,84E-03
51	produto	máximo	linear	híbrido	1,03E-04	1,11E-03
52	mínimo	máximo	linear	híbrido	7,05E-03	9,97E-03
53	produto	probabilístico	constante	híbrido	6,49E-02	8,13E-02
54	mínimo	probabilístico	constante	híbrido	5,05E-02	6,26E-02
55	produto	máximo	constante	híbrido	6,49E-02	8,13E-02
56	mínimo	máximo	constante	híbrido	5,05E-02	6,26E-02
57	produto	probabilístico	linear	retropropagação	9,45E-03	2,62E-02
58	mínimo	probabilístico	linear	retropropagação	9,31E-03	2,16E-02
59	produto	máximo	linear	retropropagação	9,45E-03	2,62E-02
60	mínimo	máximo	linear	retropropagação	9,31E-03	2,16E-02
61	produto	probabilístico	constante	retropropagação	1,14E-02	2,61E-02
62	mínimo	probabilístico	constante	retropropagação	1,18E-02	4,03E-02
63	produto	máximo	constante	retropropagação	1,14E-02	2,61E-02
64	mínimo	máximo	constante	retropropagação	1,18E-02	4,03E-02

Tabela 17: Resultados dos treinamentos para a variável pH e Função Gaussiana2.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
65	produto	probabilístico	linear	híbrido	3,00E-04	6,72E-03
66	mínimo	probabilístico	linear	híbrido	7,18E-03	1,12E-02
67	produto	máximo	linear	híbrido	6,98E-03	3,79E-02
68	mínimo	máximo	linear	híbrido	7,20E-03	1,12E-02
69	produto	probabilístico	constante	híbrido	6,99E-02	8,37E-02
70	mínimo	probabilístico	constante	híbrido	6,93E-02	6,53E-02
71	produto	máximo	constante	híbrido	6,97E-02	8,36E-02
72	mínimo	máximo	constante	híbrido	6,93E-02	6,53E-02
73	produto	probabilístico	linear	retropropagação	9,45E-03	2,62E-02
74	mínimo	probabilístico	linear	retropropagação	8,39E-03	9,16E-03
75	produto	máximo	linear	retropropagação	8,77E-03	1,90E-02
76	mínimo	máximo	linear	retropropagação	1,04E-02	1,38E-02
77	produto	probabilístico	constante	retropropagação	1,54E-02	5,31E-02
78	mínimo	probabilístico	constante	retropropagação	5,10E-02	4,05E-02
79	produto	máximo	constante	retropropagação	1,54E-02	5,31E-02
80	mínimo	máximo	constante	retropropagação	5,25E-02	4,48E-02

Tabela 18: Resultados dos treinamentos para a variável pH e Função Sigmoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (EQM)	
					Treino	Teste
81	produto	probabilístico	linear	híbrido	1,96E-03	1,44E-02
82	mínimo	probabilístico	linear	híbrido	7,03E-03	9,09E-03
83	produto	máximo	linear	híbrido	6,96E-03	1,44E-02
84	mínimo	máximo	linear	híbrido	7,03E-03	9,08E-03
85	produto	probabilístico	constante	híbrido	3,65E-02	3,87E-02
86	mínimo	probabilístico	constante	híbrido	6,07E-02	1,05E-01
87	produto	máximo	constante	híbrido	3,65E-02	3,94E-02
88	mínimo	máximo	constante	híbrido	6,07E-02	1,05E-01
89	produto	probabilístico	linear	retropropagação	1,11E-02	1,17E-02
90	mínimo	probabilístico	linear	retropropagação	1,12E-02	1,20E-02
91	produto	máximo	linear	retropropagação	1,11E-02	1,17E-02
92	mínimo	máximo	linear	retropropagação	1,12E-02	1,20E-02
93	produto	probabilístico	constante	retropropagação	2,98E-02	3,07E-02
94	mínimo	probabilístico	constante	retropropagação	5,85E-02	6,03E-02
95	produto	máximo	constante	retropropagação	2,98E-02	3,07E-02
96	mínimo	máximo	constante	retropropagação	5,85E-02	6,03E-02

Tabela 19: Resultados dos treinamentos para a variável pH e Função DSigmoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
97	produto	probabilístico	linear	híbrido	5,60E-03	4,36E-02
98	mínimo	probabilístico	linear	híbrido	7,16E-03	1,08E-02
99	produto	máximo	linear	híbrido	6,60E-03	4,37E-02
100	mínimo	máximo	linear	híbrido	7,16E-03	1,08E-02
101	produto	probabilístico	constante	híbrido	1,84E-02	4,36E-02
102	mínimo	probabilístico	constante	híbrido	5,66E-02	6,06E-02
103	produto	máximo	constante	híbrido	1,33E-02	1,77E-02
104	mínimo	máximo	constante	híbrido	5,59E-02	6,51E-02
105	produto	probabilístico	linear	retropropagação	9,10E-03	2,91E-02
106	mínimo	probabilístico	linear	retropropagação	1,04E-02	1,22E-02
107	produto	máximo	linear	retropropagação	9,10E-03	2,90E-02
108	mínimo	máximo	linear	retropropagação	1,04E-02	1,21E-02
109	produto	probabilístico	constante	retropropagação	1,06E-02	3,64E-02
110	mínimo	probabilístico	constante	retropropagação	1,48E-02	4,85E-02
111	produto	máximo	constante	retropropagação	1,21E-02	3,51E-02
112	mínimo	máximo	constante	retropropagação	1,48E-02	4,85E-02

Tabela 20: Resultados dos treinamentos para a variável pH e Função PSigmoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
113	produto	probabilístico	linear	híbrido	3,59E-03	7,00E-02
114	mínimo	probabilístico	linear	híbrido	7,16E-03	8,08E-02
115	produto	máximo	linear	híbrido	6,60E-03	7,00E-02
116	mínimo	máximo	linear	híbrido	7,16E-03	8,08E-02
117	produto	probabilístico	constante	híbrido	1,86E-02	1,14E-01
118	mínimo	probabilístico	constante	híbrido	5,50E-02	1,30E-01
119	produto	máximo	constante	híbrido	1,86E-02	1,12E-01
120	mínimo	máximo	constante	híbrido	5,50E-02	1,30E-01
121	produto	probabilístico	linear	retropropagação	9,11E-03	9,90E-02
122	mínimo	probabilístico	linear	retropropagação	1,04E-02	8,21E-02
123	produto	máximo	linear	retropropagação	9,11E-03	9,90E-02
124	mínimo	máximo	linear	retropropagação	1,04E-02	8,21E-02
125	produto	probabilístico	constante	retropropagação	1,13E-02	1,05E-01
126	mínimo	probabilístico	constante	retropropagação	1,25E-02	1,17E-01
127	produto	máximo	constante	retropropagação	1,13E-02	1,05E-01
128	mínimo	máximo	constante	retropropagação	1,25E-02	1,17E-01

Tabela 21: Resultados dos treinamentos para a variável pH e Função P.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
129	produto	probabilístico	linear	híbrido	6,54E-03	8,59E-02
130	mínimo	probabilístico	linear	híbrido	6,50E-03	4,87E-02
131	produto	máximo	linear	híbrido	6,51E-03	8,75E-02
132	mínimo	máximo	linear	híbrido	6,50E-03	4,87E-02
133	produto	probabilístico	constante	híbrido	8,05E-03	3,20E-02
134	mínimo	probabilístico	constante	híbrido	1,36E-01	3,85E-01
135	produto	máximo	constante	híbrido	8,05E-02	3,20E-01
136	mínimo	máximo	constante	híbrido	1,36E-01	3,85E-01
137	produto	probabilístico	linear	retropropagação	4,05E-02	1,19E-01
138	mínimo	probabilístico	linear	retropropagação	6,50E-02	1,71E-01
139	produto	máximo	linear	retropropagação	4,05E-02	1,19E-01
140	mínimo	máximo	linear	retropropagação	4,04E-02	8,41E-02
141	produto	probabilístico	constante	retropropagação	1,46E-02	9,07E-02
142	mínimo	probabilístico	constante	retropropagação	1,46E-02	5,65E-02
143	produto	máximo	constante	retropropagação	1,46E-02	9,06E-02
144	mínimo	máximo	constante	retropropagação	1,45E-02	5,65E-02

Tabela 22: Resultados dos treinamentos para a variável Nível e Função Triangular.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
1	produto	probabilístico	linear	híbrido	2,88E-02	1,21E-01
2	mínimo	probabilístico	linear	híbrido	5,53E-02	2,27E-01
3	produto	máximo	linear	híbrido	2,88E-02	1,21E-01
4	mínimo	máximo	linear	híbrido	5,53E-02	2,27E-01
5	produto	probabilístico	constante	híbrido	6,47E-02	2,04E-01
6	mínimo	probabilístico	constante	híbrido	4,01E-02	2,31E-01
7	produto	máximo	constante	híbrido	6,69E-02	2,39E-01
8	mínimo	máximo	constante	híbrido	4,01E-02	2,11E-01
9	produto	probabilístico	linear	retropropagação	1,34E-01	2,17E-01
10	mínimo	probabilístico	linear	retropropagação	1,71E-01	3,35E-01
11	produto	máximo	linear	retropropagação	1,34E-01	3,17E-01
12	mínimo	máximo	linear	retropropagação	1,71E-01	3,35E-01
13	produto	probabilístico	constante	retropropagação	1,34E-01	3,96E-01
14	mínimo	probabilístico	constante	retropropagação	2,17E-01	3,65E-01
15	produto	máximo	constante	retropropagação	1,34E-01	3,96E-01
16	mínimo	máximo	constante	retropropagação	2,17E-01	3,65E-01

Tabela 23: Resultados dos treinamentos para a var. nível e Função Trapezoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
17	produto	probabilístico	linear	híbrido	1,08E-01	1,93E-01
18	mínimo	probabilístico	linear	híbrido	5,85E-02	4,24E-01
19	produto	máximo	linear	híbrido	1,08E-01	1,93E-01
20	mínimo	máximo	linear	híbrido	5,85E-02	4,24E-01
21	produto	probabilístico	constante	híbrido	9,47E-02	8,68E-01
22	mínimo	probabilístico	constante	híbrido	1,13E-01	7,50E-01
23	produto	máximo	constante	híbrido	1,98E-01	7,42E-01
24	mínimo	máximo	constante	híbrido	1,13E-01	7,55E-01
25	produto	probabilístico	linear	retropropagação	3,77E-01	8,32E-01
26	mínimo	probabilístico	linear	retropropagação	3,89E-01	6,31E-01
27	produto	máximo	linear	retropropagação	3,78E-01	8,25E-01
28	mínimo	máximo	linear	retropropagação	4,14E-01	7,53E-01
29	produto	probabilístico	constante	retropropagação	5,00E-01	9,04E-01
30	mínimo	probabilístico	constante	retropropagação	4,95E-01	8,83E-01
31	produto	máximo	constante	retropropagação	4,67E-01	8,82E-01
32	mínimo	máximo	constante	retropropagação	4,91E-01	8,73E-01

Tabela 24: Resultados dos treinamentos para a var. nível e Função Sino.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
33	produto	probabilístico	linear	híbrido	3,23E-02	1,02E-02
34	mínimo	probabilístico	linear	híbrido	7,16E-02	7,92E-03
35	produto	máximo	linear	híbrido	3,23E-02	1,02E-02
36	mínimo	máximo	linear	híbrido	7,16E-02	7,92E-03
37	produto	probabilístico	constante	híbrido	3,51E-02	7,53E-02
38	mínimo	probabilístico	constante	híbrido	2,18E-01	6,90E-02
39	produto	máximo	constante	híbrido	2,07E-01	5,70E-02
40	mínimo	máximo	constante	híbrido	1,75E-01	6,90E-02
41	produto	probabilístico	linear	retropropagação	8,57E-02	1,57E-02
42	mínimo	probabilístico	linear	retropropagação	9,35E-02	1,25E-02
43	produto	máximo	linear	retropropagação	8,63E-02	1,55E-02
44	mínimo	máximo	linear	retropropagação	9,35E-02	1,25E-02
45	produto	probabilístico	constante	retropropagação	1,98E-01	5,63E-02
46	mínimo	probabilístico	constante	retropropagação	1,63E-01	3,63E-02
47	produto	máximo	constante	retropropagação	1,98E-01	5,63E-02
48	mínimo	máximo	constante	retropropagação	1,63E-01	3,63E-02

Tabela 25: Resultados dos treinamentos para a var. nível e Função Gaussiana.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
49	produto	probabilístico	linear	híbrido	2,33E-02	1,80E-02
50	mínimo	probabilístico	linear	híbrido	7,15E-02	2,79E-02
51	produto	máximo	linear	híbrido	2,33E-02	1,80E-02
52	mínimo	máximo	linear	híbrido	7,15E-02	2,79E-02
53	produto	probabilístico	constante	híbrido	1,12E-01	6,20E-02
54	mínimo	probabilístico	constante	híbrido	1,36E-01	6,57E-02
55	produto	máximo	constante	híbrido	1,14E-01	6,20E-02
56	mínimo	máximo	constante	híbrido	1,39E-01	6,57E-02
57	produto	probabilístico	linear	retropropagação	7,89E-02	2,99E-02
58	mínimo	probabilístico	linear	retropropagação	8,60E-02	2,84E-02
59	produto	máximo	linear	retropropagação	9,45E-02	4,62E-02
60	mínimo	máximo	linear	retropropagação	8,60E-02	2,84E-02
61	produto	probabilístico	constante	retropropagação	1,06E-01	6,23E-02
62	mínimo	probabilístico	constante	retropropagação	1,18E-01	4,03E-02
63	produto	máximo	constante	retropropagação	1,06E-01	6,23E-02
64	mínimo	máximo	constante	retropropagação	1,32E-01	4,77E-02

Tabela 26: Resultados dos treinamentos para a var. nível e Função Gaussiana2.

Nr. de Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
65	produto	probabilístico	linear	híbrido	3,93E-02	1,38E-02
66	mínimo	probabilístico	linear	híbrido	5,02E-02	7,74E-03
67	produto	máximo	linear	híbrido	3,93E-02	1,38E-02
68	mínimo	máximo	linear	híbrido	5,02E-02	7,74E-03
69	produto	probabilístico	constante	híbrido	4,50E-02	1,18E-01
70	mínimo	probabilístico	constante	híbrido	9,91E-02	6,43E-02
71	produto	máximo	constante	híbrido	8,50E-02	1,18E-01
72	mínimo	máximo	constante	híbrido	6,96E-02	6,38E-02
73	produto	probabilístico	linear	retropropagação	9,79E-02	9,91E-03
74	mínimo	probabilístico	linear	retropropagação	7,39E-02	9,16E-03
75	produto	máximo	linear	retropropagação	6,08E-02	2,02E-02
76	mínimo	máximo	linear	retropropagação	7,19E-02	9,16E-03
77	produto	probabilístico	constante	retropropagação	6,44E-02	5,06E-02
78	mínimo	probabilístico	constante	retropropagação	6,56E-02	3,83E-02
79	produto	máximo	constante	retropropagação	6,44E-02	5,06E-02
80	mínimo	máximo	constante	retropropagação	6,55E-02	3,50E-02

Tabela 27: Resultados dos treinamentos para a var. nível e Função Sigmoidal.

Nr. de Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
81	produto	probabilístico	linear	híbrido	6,87E-03	1,16E-02
82	mínimo	probabilístico	linear	híbrido	7,28E-03	7,52E-03
83	produto	máximo	linear	híbrido	6,84E-03	1,18E-02
84	mínimo	máximo	linear	híbrido	7,28E-03	7,52E-03
85	produto	probabilístico	constante	híbrido	1,49E-02	3,66E-02
86	mínimo	probabilístico	constante	híbrido	8,74E-02	6,36E-02
87	produto	máximo	constante	híbrido	1,49E-02	3,66E-02
88	mínimo	máximo	constante	híbrido	8,74E-02	6,36E-02
89	produto	probabilístico	linear	retropropagação	9,07E-03	7,92E-03
90	mínimo	probabilístico	linear	retropropagação	9,09E-03	8,13E-03
91	produto	máximo	linear	retropropagação	9,07E-03	7,92E-03
92	mínimo	máximo	linear	retropropagação	9,09E-03	8,13E-03
93	produto	probabilístico	constante	retropropagação	1,51E-02	1,54E-02
94	mínimo	probabilístico	constante	retropropagação	2,37E-02	2,43E-02
95	produto	máximo	constante	retropropagação	1,51E-02	1,54E-02
96	mínimo	máximo	constante	retropropagação	2,37E-02	2,43E-02

Tabela 28: Resultados dos treinamentos para a var. nível e Função DSigmoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
97	produto	probabilístico	linear	híbrido	6,70E-03	2,66E-02
98	mínimo	probabilístico	linear	híbrido	7,19E-03	7,78E-03
99	produto	máximo	linear	híbrido	6,70E-03	2,66E-02
100	mínimo	máximo	linear	híbrido	7,19E-03	7,78E-03
101	produto	probabilístico	constante	híbrido	2,22E-02	6,85E-02
102	mínimo	probabilístico	constante	híbrido	5,50E-02	5,99E-02
103	produto	máximo	constante	híbrido	2,22E-02	6,85E-02
104	mínimo	máximo	constante	híbrido	6,30E-02	6,51E-02
105	produto	probabilístico	linear	retropropagação	8,37E-03	1,26E-02
106	mínimo	probabilístico	linear	retropropagação	9,34E-03	1,91E-02
107	produto	máximo	linear	retropropagação	8,37E-03	3,26E-02
108	mínimo	máximo	linear	retropropagação	9,34E-03	1,91E-02
109	produto	probabilístico	constante	retropropagação	1,73E-02	4,69E-02
110	mínimo	probabilístico	constante	retropropagação	1,20E-02	3,91E-02
111	produto	máximo	constante	retropropagação	1,73E-02	4,69E-02
112	mínimo	máximo	constante	retropropagação	1,20E-02	3,91E-02

Tabela 29: Resultados dos treinamentos para a var. nível e Função PSigmoidal.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
113	produto	probabilístico	linear	híbrido	6,70E-03	2,66E-02
114	mínimo	probabilístico	linear	híbrido	7,19E-03	7,78E-03
115	produto	máximo	linear	híbrido	6,70E-03	2,66E-02
116	mínimo	máximo	linear	híbrido	7,19E-03	7,78E-03
117	produto	probabilístico	constante	híbrido	2,23E-02	6,59E-02
118	mínimo	probabilístico	constante	híbrido	6,30E-02	6,51E-02
119	produto	máximo	constante	híbrido	2,23E-02	6,87E-02
120	mínimo	máximo	constante	híbrido	6,30E-02	6,51E-02
121	produto	probabilístico	linear	retropropagação	8,38E-03	1,26E-02
122	mínimo	probabilístico	linear	retropropagação	1,04E-02	1,21E-02
123	produto	máximo	linear	retropropagação	8,37E-03	1,26E-02
124	mínimo	máximo	linear	retropropagação	9,35E-03	9,15E-03
125	produto	probabilístico	constante	retropropagação	1,72E-02	4,67E-02
126	mínimo	probabilístico	constante	retropropagação	1,19E-02	3,90E-02
127	produto	máximo	constante	retropropagação	1,72E-02	4,58E-02
128	mínimo	máximo	constante	retropropagação	1,19E-02	3,90E-02

Tabela 30: Resultados dos treinamentos para a variável nível e Função P.

Nr. do Ensaio	Método 'e'	Método 'ou'	Tipo de saída da FP	Método de Otimização	Desempenho pH (MSE)	
					Treino	Teste
129	produto	probabilístico	linear	híbrido	6,06E-03	9,85E-02
130	mínimo	probabilístico	linear	híbrido	5,92E-03	6,64E-02
131	produto	máximo	linear	híbrido	6,06E-03	9,85E-02
132	mínimo	máximo	linear	híbrido	5,92E-03	6,64E-02
133	produto	probabilístico	constante	híbrido	7,60E-03	1,75E-01
134	mínimo	probabilístico	constante	híbrido	1,25E-01	1,60E-01
135	produto	máximo	constante	híbrido	7,60E-02	1,75E-01
136	mínimo	máximo	constante	híbrido	1,25E-01	1,60E-01
137	produto	probabilístico	linear	retropropagação	4,07E-02	1,52E-01
138	mínimo	probabilístico	linear	retropropagação	5,43E-02	1,86E-01
139	produto	máximo	linear	retropropagação	3,86E-02	1,48E-01
140	mínimo	máximo	linear	retropropagação	4,00E-02	1,13E-01
141	produto	probabilístico	constante	retropropagação	1,49E-02	1,08E-01
142	mínimo	probabilístico	constante	retropropagação	1,58E-02	1,04E-01
143	produto	máximo	constante	retropropagação	1,49E-02	1,08E-01
144	mínimo	máximo	constante	retropropagação	1,58E-02	1,04E-01

4.5 Desempenho do sistema de controle

Para análise do desempenho dos controladores neuro-fuzzy, foram simulados os conjuntos de configurações fuzzy que mais se destacaram em relação ao treinamento do controlador representados pelas Tabelas 11 e 12. As várias estruturas consideradas no estudo proposto tiveram seus desempenhos comparados e podem ser verificadas nas Figuras 19 e 20.




Figura 19: Desempenhos dos controladores ANFIS para a variável pH.




Figura 20: Desempenhos dos controladores ANFIS para a variável nível do tanque.

Os resultados das simulações para os vários grupos de regras mostram que o melhor desempenho alcançado considerando todos os conjuntos de dados testados, tanto para a variável pH quanto para a variável nível do tanque, foram: (i) funções de pertinência Gaussiana Simétrica e Gaussiana não Simétrica; (ii) método ‘OU’ (probabilístico); (iii) método ‘E’ (produto), (iiii) tipo de saída da FP (linear) e; (iiiii) o método de otimização (híbrido).

Para a variável pH, observou-se que a função triangular e Função P, usando o método ‘E’ T_{min} - mínimo e ‘OU’ S_{PA} – probabilístico, apresentaram-se mais eficientes que os demais configurações testadas. Já para a variável nível do tanque, apenas a Função P necessitou dos operadores ‘E’ T_{min} - mínimo e ‘OU’ S_{PA} – probabilístico para alcançar maior desempenho. Notou-se que nenhuma das configurações utilizando o método T-norma máximo, obteve destaque no de desempenho para as funções de pertinências simuladas.

As Figura 21 a 23 ilustramos melhores desempenhos alcançados para cada função de pertinência adotada quanto a ação de controle para a variável pH e para melhor visualização, optou-se por agrupar três curvas por gráfico comparativo.

Nas Figuras 21 (a) e (b), é possível verificar que a função de pertinência triangular responde mais rapidamente a ação de controle que os demais conjuntos avaliados porém, apresentando *off-set* para alguns distúrbios. Tanto as funções triangular e trapezoidal, em alguns casos, não alcançaram um desempenho satisfatório se distanciando da referência do ajuste manual realizado pelo especialista da planta.

As figuras 22 e 23 ilustram a ação de controle usando as funções Gaussiana e diferença sigmoidal que apresentaram as menores taxas de erro e desempenhos superiores as demais curvas testadas. Porém, as funções Gaussiana não simétrica, sigmoidal, produto sigmoidal e função P podem ser também consideradas aceitáveis em termos de desempenho para o processo estudado devido as taxas de erros não serem consideradas discrepantes a 10^{-3} .





Figura 21: (a) Ação do controlador para a variável manipulada $Fb [F_{\text{NH}_4\text{OH}}]$, funções triangular, trapezoidal e sino. (b) Curva ampliada no tempo 900s.





Figura 22: (a) Ação do controlador para a variável manipulada $Fb [F_{\text{NH}_4\text{OH}}]$, funções Gauss, Gauss2 e sigmoidal. (b) Curva ampliada no tempo 900s.





Figura 23: (a) Ação do controlador para a variável manipulada F_b [$F_{\text{NH}_4\text{OH}}$], funções Dsigmoidal, Psigmoidal e P. (b) Curva ampliada no tempo 900s.





Figura 24: (a) Ação do controlador para a variável manipulada A_v (Abert. valv.), funções triangular, trapezoidal e sino. (b) Curva ampliada no tempo 900s.





Figura 25: (a) Ação do controlador para a variável manipulada A_v (Abert. valv.), funções Gauss, Gauss2 e sigmoidal. (b) Curva ampliada no tempo 900s.





Figura 26: (a) Ação do controlador para a variável manipulada A_v (Abert. valv.), funções Dsigmoidal, Psigmoidal e P. (b) Curva ampliada no tempo 900s.

Em relação a variável nível do tanque, nas Figuras 24, 25 e 26 é possível observar que as configurações contendo as funções de pertinências Sino, Gaussiana, diferença sigmoidal e produto sigmoidal foram as que apresentaram melhor comportamento de controle em relação ao *set-point* e a curva de referencia manual. Estas funções não apresentaram *off-set* ou *overshoot* significativos, sendo consideradas aceitáveis para a manutenção do nível do tanque. A função trapezoidal, sigmoidal e função P foram as curvas que apresentaram os piores resultados. Nota-se que para algumas perturbações não foi possível manter a estabilidade do controle.

Embora as Figuras 19 e 20 destacam duas estruturas, para ambas as variáveis, com sendo as estruturas que obtiveram os melhores desempenhos encontrados, é possível notar que os valores obtidos são bem próximos. Então, considerando os resultados do menor EQM de treinamento e, no compromisso razoável entre a precisão e a complexidade da estrutura, o ensaio 49 é escolhido para representar o desempenho para as duas variáveis controladas.

Desta forma, observou-se que, os conjuntos de regras que proporcionaram os melhores ajustes para os controladores neuro-fuzzy e, conseqüentemente, oferecem os desempenhos de maior precisão em termos da ação de controle para o processo de neutralização foram os que utilizaram a função de pertinência Gaussiana Simétrica; o método ‘OU’ (probabilístico); o método ‘E’ (produto), o tipo de saída da FP (linear) e o método de otimização (híbrido) para ambas as variáveis controladas.

Para o conjunto de configurações final encontrado, percebeu-se ações de controle mais rápidas e com *overshoot* menor quando comparadas as demais configurações avaliadas e que o ajuste de controle realizado pelo especialista da planta (Ajuste Manual). Esses resultados podem ser verificados nas Figuras 27 a 32 em relação as variáveis controladas.




Figura 27: Controle regulatório ANFIS para variável controlada pH e função Gaussiana simétrica.




Figura 28: Ajuste manual vs controle ANFIS para variável manipulada F_b usando função gaussiana simétrica.




Figura 29: Destaque do ajuste manual vs controle ANFIS para variável manipulada F_b usando função gaussiana simétrica.




Figura 30: Controle regulatório ANFIS para variável controlada Abertura de Válvula (A_v) e função Gaussiana simétrica.




Figura 31: Ajuste manual vs controle ANFIS para variável manipulada A_v usando função gaussiana simétrica.




Figura 32: Destaque do ajuste manual vs controle ANFIS para variável manipulada A_v usando função gaussiana simétrica.

Capítulo 5

5.1 Conclusão

Neste estudo, um sistema de neutralização de pH foi projetado em ambiente Matlab®/Simulink para a realização de testes por simulação numérica usando controladores ANFIS treinados com um conjunto de dados não convencional, criado manualmente por um operador humano a partir de um sistema de supervisão industrial elaborado em *InduSoft Web Studio*® (IWS).

Os resultados da simulação do processo de neutralização sob a atuação dos controladores ANFIS foram utilizados para analisar o efeito das regras do controle neuro-fuzzy sobre o desempenho do processo de neutralização, para o controle das variáveis pH e nível do tanque.

Como forma de avaliar cada controlador do modelo estudado, foram empregados critérios de desempenho com base no erro como *IAE*, *ISE*, *ITAE* e *ITSE*. Além destes critérios, vários tipos de estruturas de entrada para o controlador foram estudadas, a fim de alcançar a melhor estratégia de controle.

Portanto, pode-se concluir com este estudo que, as funções Gaussiana Simétrica, Gaussiana Não Simétrica e Triangular apresentaram desempenhos superiores as demais funções de pertinência avaliadas. Porém, os resultados para as várias configurações formados não apresentaram um único e distinto conjunto de parâmetros. As variações encontradas quanto à taxa do erro e ITAE pode tornar possível a utilização

de mais de um tipo de conjuntos de parâmetros no controlador com desempenho aceitável.

Para as configurações de propriedades dos conjuntos fuzzy, os operadores ‘E’ e ‘OU’ mostraram exercer certa influência ao conjunto de dados, porém não o suficiente para promover ganhos significativos na precisão do controlador. Notou-se que, para o estudo de caso escolhido, pouca diferença no potencial do controlador foi agregado, porém há influência na escolha dos operadores ao sintonizar um controlador neuro-fuzzy. Essa influência reduzida demonstra que, a maior influência do ajuste dos controladores que utilizam o método Sugeno, vem do aprendizado realizado pela rede neural, bem como, da escolha da função de pertinência.

Com isso, os resultados obtidos também evidenciaram que a escolha da função de pertinência detém forte influência sobre as demais configurações adotadas dentro do conjunto de parâmetros do controlador, o que já era esperado, uma vez que é a função de pertinência que associa cada elemento do conjunto a um grau de pertinência do mesmo.

Quanto ao tipo de função de saída da função de pertinência, linear ou constante, percebeu-se que ao alterar o tipo de saída para o conjunto de dados estudados para ambas as variáveis controladas (conforme Tabelas 13 ao 30), um decréscimo no desempenho do controlador é apresentado, destacando a saída linear como preferência de aplicação.

No que diz respeito ao método de otimização, observou-se que o método híbrido acarretou melhor resposta quando comparado ao método de retropropagação.

Para a hipótese considerada, não foi possível concluir que os parâmetros de configuração considerados nas etapas de fuzificação, inferência e defuzificação de um controlador neuro-fuzzy possuem influências determinantes no desempenho de controle aplicado em um processo químico de neutralização. Notou-se neste estudo que foi possível obter um desempenho satisfatório do controlador ANFIS apenas contemplando o sistema de tomada de decisão, ou seja, as funções de pertinência. Para as demais configurações, observou-se pouca significância em termos de precisão no desempenho do controlador, sendo possível manter padrão os métodos de fuzificação e defuzificação disponibilizados pelo software *Matlab®/Simulink*.

O sistema supervisorio virtual desenvolvido permitiu treinar e aplicar em tempo real os procedimentos e situações vivenciados em plantas reais, excluindo condições de risco. Através do estudo de caso, verificou-se a potencialidade da metodologia, pois a ferramenta desenvolvida pode minimizar retrabalhos, acidentes e perdas, reduzindo o tempo para obtenção de dados do processo e propiciar o aumento do entendimento do manuseio da planta pelo operador. Adicionalmente, essa metodologia pode ser replicada em outras plantas industriais.

5.2 Sugestões para trabalhos futuros

A análise do efeito das regras de controle ANFIS sobre o desempenho do processo de neutralização apresentou resultados significativos, sendo capaz de obter um desempenho satisfatório para o conjunto de parâmetros ajustados no controlador Sugeno. Desta forma, a seguir, algumas sugestões para trabalhos futuros são apresentadas.

Como estudo futuro, podem ser considerados novos modelos com diferentes graus de linearidade para então destacar as influências relativas a metodologia escolhida e/ou ao modelo utilizado.

Sugere-se também analisar os efeitos dos conjunto de configurações dos controladores neuro-fuzzy no desempenho de controle de processo usando o método *sub clustering*.

Desenvolver um algoritmo de identificação da melhor estrutura e conjunto de regras para o controlador ANFIS contemplando todas as possibilidades de configuração, ou seja, as etapas de defuzificação, inferência, defuzificação, metodologias de aplicação e otimização para utilização como critério de sintonia de controladores baseados em regras.

Referências Bibliográficas

ADROER, M. et al. Wastewater neutralization control based in fuzzy logic: experimental results. **Industrial and Engineering Chemistry Research**, Spain, v. 38, p. 2709-2719, May 1999.

ANDRADE, M. **Estudo para aprimoramento da operação de Controladores Semafóricos Fuzzy**. Dissertação de Mestrado apresentada a Faculdade de Tecnologia. Universidade de Brasília. DF, p. 137. 2004.

ANDRADE, M. **Estudos de elementos de controladores semafóricos fuzzy com aplicação para operação em rede aberta**. Dissertação de Mestrado apresentada a Faculdade de Tecnologia. Universidade de Brasília. DF, p. 238. 2009.

FILETI, A. M. F. et al. Experimental investigations on fuzzy logic for process control. **Control Engineering Practice**, Campinas, p. 1149–1160, Março 2007.

FONSECA, C. A. G. **Estrutura ANFIS Modificada para Identificação e Controle de Plantas com Ampla Faixa de Operação e não Linearidade Acentuada**. Tese de Doutorado apresentada a Faculdade de Engenharia Elétrica e de Computação. Universidade Federal do Rio Grande do Norte. Natal, RN. 2012.

FRAGIADAKIS, N. G.; TSOUKALAS, V. D.; PAPAZOGLU, V. J. **An adaptive neuro-fuzzy inference system (anfis) model for assessing occupational risk in the shipbuilding industry**. *Safety Science*. [S.l.], p. Volume 63, p.226-235. 2014.

GARRIDO, R.; ADROER, R.; POCH, M. Wastewater neutralization control based in fuzzy logic: simulation results. **Industrial and Engineering Chemistry Research**, Spain, v. 36, p. 1665-1674, may 1997.

HO, W. H. et al. Adaptive network-based fuzzy inference system for prediction of surface roughness in end milling process using hybrid Taguchi-genetic learning algorithm. **Department of Computer Science and Institute of Engineering Science and Technology. Expert Systems with Applications**, 36, Taiwan, p. 3216–3222, 2009.

JACQUES, M. A. P. et al. The Impact of Different Approximate Reasoning Methods on Fuzzy Signal Controllers. **Anais do 13th Mini-Euroconference**, Bari-Itália, p. 184-192, june 2002.

JANG, J. S. R. ANFIS: Adaptive network based fuzzy inference system. **IEEE Transactions on Systems, Man and Cybernetics**, California, v. 23, No. 3, p. 665-685, May/June 1993.

JANG, J. S.; GULLEY, N. Fuzzy Logic Toolbox – For use Matlab®/Simulink. **Natick Mauss.: the MathWorks, Inc.**, 1995.

LI, H. E. G. H. D. **Conventional fuzzy control and its enhancement**. IEEE Transactions on Systems, Man and Cybernetics_part B: Cybernetics. [S.l.], p. 791- 797. 1996.

LOTFI, A.; TSOI, A. C. Importance of Membership Functions: A Comparative Study on Different Learning Methods for Fuzzy Inference Systems. **Department of Electrical and Computer Engineering University of Queensland**, Brisbane-Australia, p. 4072, 1994.

MAMDANI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Logic Controller. **International Journal of Man-Machine Studies**, 8, p. 1-13, 1975.

MÉSZÁROS, A.; CIRKA LUBOS, S. L. **Intelligent control of a pH process**. Institute of Information Engineering, Automation and Mathematics, Faculty of Chemical and Food Technology, Slovak University of Technology in Bratislava. Bratislava, p. SK-812 37. 2009.

MOHAMAD, S.; ISHAK, A. A.; AISHAH, S. S. A. **Design of Fuzzy Logic Controller for Overdamped Temperature Response of a Process Air Heater System**. Faculty of Chemical Engineering University Teknologi MARA. Shah Alam. 2011.

NUNES, T. C. M.; RIBEIRO, P. B. **Mineração de dados utilizando sistemas adaptativos de inferência neuro-fuzzy**. Faculdade de Tecnologia de Bauru (Fatec Bauru). Bauru/SP. 2013.

PAGLIOSA, A. L. **Obtenção das Funções de Pertinência de um Sistema Neurofuzzy Modificado pela Rede de Kohonen.** Dissertação de Mestrado, PGAI/UEDESC. Joinville, Santa Catarina. 2003.

SHILLT, P. C.; AKHAND, M. A. H.; MURASET, K. **Simultaneous Design of Membership Functions and Rule Sets for Type-2 Fuzzy Controllers using Genetic Algorithms.** Dept. of System Design Engineering, University of Fukui, Japan and Dept. of Computer science and Engineering, KUET, Bangladesh. [S.l.]. 2011.

SHIP-PENG-LO. **An adaptive-network based fuzzy inference system for prediction of workpiece surface roughness in end milling.** Department of Mechanical Engineering, De Lin Institute of Technology, 1,380LN. Chin-yung Road, Tucheng, Taipei Hsien, Taiwan, p. 236. 2003.

SIMÕES, M. G.; SHAW, I. S. **Controle e Modelagem FUZZY.** 2^a. ed. São Paulo: FAPESP, 2007.

SIVAKUMAR, R.; SAHANA, C.; SAVITHA, P. A. Design of ANFIS based Estimation and Control for MIMO Systems. **International Journal of Engineering Research and Applications (IJERA)**, India, v. 2, Issue 3, p. 2803-2809, May-Jun 2012.

STEPHANOPOULOS, G. **Chemical process control:** An introduction to theory and practice. New Jersey: Prentice-Hall International Inc, v. 696p., 1984.

SUN, W. et al. **Case study of performance evaluation of ground source heat pump system based on ANN and ANFIS models.** Thermal Engineering. [S.l.]. 2015.

TAKAGI, S.; SUGENO, M. Fuzzy Identification of Fuzzy Systems and its Application to Modeling and Control. **IEEE Transaction on System, Man and Cybernetics**, v. 15, p. 116-132, 1985.

USTA, M. A.; AKYAZI, O.; ALTAS, I. H. **Design and Performance of Solar Tracking System with Fuzzy Logic Controller Used Different Membership Functions.** Karadeniz Technical University. Trabzon/Turkey. 2011.

ZADEH, L. A. Outline of a New Approach to the Analysis of Complex Systems and Decision Process. **IEEE Transactions on Systems, Man and Cybernetics**, California, v. SMC-3, No. 1., p. 28-44, January 1973.