



PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA

# **CONTROLE NEURAL ADAPTATIVO HÍBRIDO INDIRETO: APLICAÇÃO A UM SISTEMA INDUSTRIAL**

**Ricardo Feichas Santos**

Dissertação submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia do Centro Universitário do Leste de Minas Gerais, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Industrial.

**Área de Concentração:** Processos Industriais

**Orientador(es):** Prof. Roselito de Albuquerque Teixeira, Dr. - PPGE/Unileste-MG  
Prof. Marcelo Vieira Corrêa, Dr. - PPGE/Unileste-MG.

Coronel Fabriciano, outubro de 2009

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.





PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA

# **CONTROLE NEURAL ADAPTATIVO HÍBRIDO INDIRETO: APLICAÇÃO A UM SISTEMA INDUSTRIAL**

**Ricardo Feichas Santos**

**Banca:**

Prof. Marcelo Vieira Corrêa, Dr. - PPGE/Unileste-MG - Orientador e Presidente da banca

Prof. Roselito de Albuquerque Teixeira, Dr. - PPGE/Unileste-MG - Co-orientador

Prof. Cláudio Garcia, Dr. - DETC/ Escola Politécnica/USP - Membro Externo

Prof. Dair José de Oliveira, Dr. - PPGE/Unileste-MG



*À Deus em primeiro lugar,  
à minha esposa Ana Silvia  
e aos meus pais Maria Aparecida e Antonio Roberto.*



# Agradecimentos

Em primeiro lugar agradeço à DEUS por me proporcionar saúde e paz nestes últimos anos, proporcionando-me toda a capacidade para enfrentar os obstáculos que durante este caminho não foram poucos.

Agradeço à minha esposa, Ana Silvia, pelo amor, apoio e orações. Agradeço ainda pela compreensão que este trabalho consumiria muito tempo de seu companheiro, e que ela passaria por alguns períodos solteira.

Agradeço à meus pais, Maria Aparecida e Antonio Roberto, por toda a dedicação e amor dispendidos na criação de seus filhos, não somente à mim. O conforto de uma vida familiar feliz somado à educação em boas escolas proporcionaram-me um crescimento cultural e pessoal digno.

Agradeço aos meus irmãos de sangue, Daniel e Fernanda, e aos meus irmãos "avulsos", Ana Carolina, Rosiane e Nilton, que apesar da distância e de serem mais novos, me ensinaram, mesmo que indiretamente, em seus momentos de vitória, me mostraram que sempre estamos aprendendo.

Agradeço aos professores Marcelo Vieira Corrêa e Roselito de Albuquerque Teixeira, meus orientadores, pela amizade e dedicação, principalmente nesta reta final, me passando seus conhecimentos e dando o apoio e força necessários para conclusão deste trabalho.

Agradeço ao professor Maitelli, da Universidade Federal do Rio Grande do Norte, que me deu alguma orientação no início dos estudos me enviando uma dissertação sobre o tema.

Agradeço ao Joilson, aluno do Maitelli, que pode compartilhar comigo um pouco de sua experiência. Nos conhecemos no CBA (Congresso Brasileiro de Automática) de 2008, em Juiz de Fora, onde presenciei a apresentação de um trabalho dele sobre o tema estudado nesta dissertação.

Agradeço aos meus colegas de mestrado que juntos caminharam comigo no desenvolvimento de suas pesquisas. Em especial agradeço ao Felipe e ao Silas, pelo apoio e troca de experiências



e pela ajuda na manipulação da planta de neutralização de pH do UnilesteMG.

Agradeço aos meus colegas de superintendência, Paulo Soares, Samuel, Paulo Pires, Ageu, Nely e o Carlos da Sankyu, o pessoal da Instrumentação da Usiminas em Ipatinga, que disponibilizaram seu tempo e conhecimento sobre a planta de regeneração de ácido clorídrico e me acompanhando em todos os testes realizados ali.

Agradeço aos operadores da planta de regeneração de ácido clorídrico da Usiminas, lotados na Sankyu, pelo apoio e compreensão durante os testes.

Agradeço aos meus colegas de escritório, em especial ao Wanderley e ao Cid, que durante esta caminhada me deram apoio, orientação, força e experiência. Agradeço ainda pela compreensão de todos nos momentos em que estive fora das atividades de rotina para me empenhar no desenvolvimento deste trabalho.

Agradeço também à Usiminas por me dar esta oportunidade e o apoio necessários ao desenvolvimento deste trabalho.

*"De que vale ao homem conquistar todos os tesouros da terra e perder sua alma?"*

***Jesus Cristo***



# Resumo

Neste trabalho são apresentadas implementações da estratégia de controle adaptativo neural proposta em Maitelli e Filho (2003a,b). A estratégia proposta é chamada Controle Adaptativo Híbrido Indireto, um esquema com base em identificador e treinamento *online*. O esquema baseia-se na obtenção do modelo da planta numa região de operação através de um identificador neural. Com o modelo obtido são extraídos os pesos da rede com o intuito de calcular o seu Jacobiano e, com base nele, ajustar o próximo sinal de controle de forma que a saída da planta convirja para o sinal de referência. Como contribuição deste trabalho foi buscada sua implementação no ambiente industrial que, pelo menos na indústria brasileira, não foi encontrada referência. Outra contribuição deste trabalho é uma análise do comportamento do controlador com base na variação dos parâmetros da rede neural (o número de neurônios da camada escondida e o número de atrasos da planta usados na entrada) e também com base na variação da janela de dados disponíveis para o treinamento.

O esquema de controle foi aplicado em dois sistemas reais: uma planta piloto de neutralização de pH e uma planta industrial de regeneração de ácido clorídrico. A estratégia de controle utilizada apresentou resultado oscilatório para a planta piloto na região de neutralização, mas apresentou bons resultados para o teste de rastreabilidade na planta industrial.

Palavras-chave: Controle neural, controle adaptativo, neutralização de pH, regeneração de ácido clorídrico.



# Abstract

This dissertation presents implementations of the adaptive neural control strategy proposed in (Maitelli e Filho, 2003a,b). The proposed technique is called Adaptive Hybrid Indirect Control, an adaptive control based on identifier and online training. The scheme is based on identify the plant model on a region of operation using a neural network. With the obtained model, the weights of the neural network are extracted in order to calculate its Jacobian and, based on it, adjust the next control signal so that the output of the plant converges to the reference signal. As contribution of this work was pursued its implementation in the industrial environment. At least in the brazilian industry, was not found reference. Another contribution of this work is an analysis of the behavior of the controller based on the variation of the parameters of the neural network (the number of neurons in the hidden layer and the number of delays used in the input) and also based on the variation of the window of data available for training.

The control scheme was applied to two real systems: a pilot plant for neutralization of pH and an industrial regeneration plant of hydrochloric acid. The control strategy used had an oscillatory result for the pilot plant in the neutralization region, but good results for traceability test in the industrial plant.

key words: Neural control, adaptive control, pH neutralization, regeneration of hydrochloric acid.



# Sumário

<b>Resumo</b>	<b>xi</b>
<b>Abstract</b>	<b>xiii</b>
<b>Lista de Figuras</b>	<b>xvii</b>
<b>Lista de Símbolos</b>	<b>xxii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Uma breve revisão histórica . . . . .	1
1.2 Motivação . . . . .	3
1.3 Objetivos . . . . .	3
1.4 Organização do texto . . . . .	4
<b>2 Controle Adaptativo</b>	<b>5</b>
2.1 Introdução . . . . .	5
2.2 Vantagens e Desvantagens de um Sistema de Controle Adaptativo . . . . .	6



2.2.1	Vantagens . . . . .	6
2.2.2	Desvantagens . . . . .	7
2.3	Classificações para Controladores Adaptativos . . . . .	7
2.3.1	Controle Adaptativo Baseado em Identificador . . . . .	8
2.3.2	Controle Adaptativo Não Baseado em Identificador . . . . .	9
2.3.3	Controle Utilizando Redes Neurais . . . . .	10
2.4	Algumas Estratégias de Controle Adaptativo . . . . .	11
2.4.1	Controle Adaptativo por Modelo de Referência . . . . .	11
2.4.2	Controle Auto Ajustável (STR) . . . . .	12
<b>3</b>	<b>Redes Neurais para Controle</b>	<b>13</b>
3.1	Introdução . . . . .	13
3.2	Identificação de Sistemas Dinâmicos Usando Redes Neurais . . . . .	13
3.2.1	False Nearest Neighbor (FNN) . . . . .	17
3.2.2	Escolha do tempo de amostragem . . . . .	18
<b>4</b>	<b>A Estratégia de Controle</b>	<b>21</b>
4.1	Introdução . . . . .	21
4.2	O Esquema de Controle . . . . .	22
4.2.1	A Lei de Controle . . . . .	24
4.2.2	Cálculo do Jacobiano . . . . .	25

	xv
4.2.3	Taxa de Aprendizado Adaptativa . . . . . 27
4.2.4	Teorema de Estabilidade e Análise de Robustez . . . . . 29
4.2.5	O Algoritmo para Implementação do Esquema de Controle . . . . . 34
<b>5</b>	<b>Aplicações da Estratégia de Controle em Plantas Simuladas e Piloto</b> <b>37</b>
5.1	Introdução . . . . . 37
5.2	Aplicação em Um Sistema Não-linear Real . . . . . 38
5.2.1	Conceitos Básicos sobre o Processo de Neutralização de pH . . . . . 38
5.2.2	A Planta Piloto . . . . . 40
5.2.3	Aplicação no Modelo da Planta Piloto . . . . . 42
5.2.4	Aplicação na Planta Piloto Real . . . . . 54
<b>6</b>	<b>Aplicação da Técnica de Controle Proposta em uma Planta Industrial</b> <b>57</b>
6.1	Introdução . . . . . 57
6.2	O Processo de Regeneração de Ácido Clorídrico . . . . . 58
6.3	Aplicação no Controle de Vazão de Água da Coluna de Lavagem do Gás HCl . 61
6.3.1	Resultados Obtidos . . . . . 65
<b>7</b>	<b>Considerações Finais</b> <b>69</b>
7.1	Conclusões . . . . . 69
7.2	Sugestões para trabalhos futuros . . . . . 70



# Lista de Figuras

2.1	Esquema Geral para Controladores Adaptativos . . . . .	8
2.2	Estrutura para o Controle Adaptativo Direto . . . . .	8
2.3	Estrutura para o Controle Adaptativo Indireto . . . . .	9
2.4	Estratégia <i>Gain Scheduling</i> . . . . .	10
2.5	Esquema de Controle Adaptativo Híbrido . . . . .	11
2.6	Esquema de Controle Adaptativo Não-Híbrido . . . . .	11
2.7	Esquema MRAC . . . . .	12
2.8	Esquema STR . . . . .	12
3.1	Exemplo de Rede Neural para Identificação . . . . .	14
3.2	Esquema Geral NNARX - <i>Neural Network AutoRegressive with eXogeneous inputs</i> . . . . .	15
3.3	Esquema NNARX para Identificação . . . . .	16
4.1	Esquema de controle neural adaptativo utilizado . . . . .	22
4.2	Rede neural utilizada no esquema de controle . . . . .	23
4.3	Arquiteturas Paralelo (a) e Série-Paralelo (b). . . . .	24
4.4	Esquema de rede neural utilizado para o desenvolvimento do cálculo do Jacobiano . . . . .	26
4.5	Rede neural para o exemplo de aplicação do Lema de Estabilidade . . . . .	31

4.6	Algoritmo para implementação da estratégia de controle . . . . .	35
5.1	Foto frontal da planta piloto de neutralização de pH . . . . .	38
5.2	Curva estática típica de um sistema de neutralização de pH sem adição de tampão	40
5.3	Curva estática típica de um sistema de neutralização de pH com adição de tampão	40
5.4	Esquema da planta piloto de neutralização de pH . . . . .	41
5.5	Relação Volts x Vazão para a bomba Q1 (ácido) . . . . .	41
5.6	Relação Volts x Vazão para a bomba Q2 (tampão) . . . . .	42
5.7	Relação Volts x Vazão para a bomba Q3 (base) . . . . .	42
5.8	Sinal de referência utilizado nas simulações com a planta de neutralização de pH	43
5.9	Dados de entrada (a) e saída (b) simulados para o procedimento de determi- nação do tempo de amostragem . . . . .	43
5.10	Autocovariâncias obtidas no procedimento de determinação do tempo de amostragem. (a) Autocovariância linear. (b) Autocovariância não-linear. . . . .	44
5.11	Resultado do algoritmo FNN (percentual de falsos vizinhos x ordem) . . . . .	45
5.12	Índice de desempenho médio com relação à variação do número de neurônios da camada escondida (90 amostras para a janela de treinamento) . . . . .	46
5.13	Índice de desempenho médio com relação à variação do tamanho da janela de treinamento (20 neurônios na camada escondida) . . . . .	47
5.14	Resultado para 20 neurônios e 90 amostras de treinamento . . . . .	48
5.15	Resultado para a janela de treinamento com 20 amostras. (a) Linha contínua: valor de pH. Linha tracejada: sinal de referência. (b) Sinal de controle. . . . .	48
5.16	Resultado para a janela de treinamento com 90 amostras. (a) Linha contínua: valor de pH. Linha tracejada: sinal de referência. (b) Sinal de controle. . . . .	49
5.17	Variação do índice de desempenho com relação ao tempo de amostragem . . . .	49
5.18	Variação do índice de desempenho com relação ao número de regressores da entrada e da saída . . . . .	50

5.19	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 1. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	51
5.20	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 2. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	51
5.21	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 3. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	52
5.22	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 4. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	52
5.23	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 6. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	53
5.24	Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 9. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle. . . . .	53
5.25	Resultado para aplicação do controle neural adaptativo na planta piloto de neutralização de pH . . . . .	54
5.26	Comparação do efeito do tampão na planta de neutralização de pH para o caso real (a) e para o modelo (b) . . . . .	55
5.27	Resultado da simulação do modelo da planta de neutralização de pH sem a adição de solução tampão. (a) Linha contínua: Valor do pH. Linha tracejada: sinal de referência. (b) Sinal de controle. . . . .	56
6.1	Diagrama esquemático do reator do processo de regeneração de ácido clorídrico	60
6.2	Diagrama esquemático do processo de regeneração de ácido clorídrico . . . . .	61
6.3	Diagrama esquemático: conexão do <i>notebook</i> ao sistema Yokogawa . . . . .	62

6.4	Chave de seleção entre o controlador convencional do CS3000 e o controlador neural adaptativo implementado no Matlab instalado em um notebook que acessa o sistema via rede Ethernet TCP/IP . . . . .	63
6.5	Fluxograma da estratégia de controle implementada no controle de vazão de água da coluna de lavagem de ácido da planta de regeneração de ácido clorídrico da Usiminas . . . . .	64
6.6	Resultado para o controlador PID. (a) Linha contínua: Sinal de vazão de água da coluna. Linha tracejada: Sinal de referência. (b) Sinal de controle (100% - valor de abertura da válvula) . . . . .	65
6.7	Resultado para o Controle Neural Adaptativo. (a) Linha contínua: Sinal de vazão de água da coluna. Linha tracejada: Sinal de referência. (b) Sinal de controle (100% - valor de abertura da válvula) . . . . .	66

# Lista de Símbolos

$E[x]$	Esperança matemática de uma variável aleatória $x$
$\mathbf{R}$	Espaço dos números reais
$\mathbf{R}^{k \times n}$	Espaço das matrizes reais $k \times n$
$q$	Operador de atraso: $qf(k) = f(k + 1)$ , $q^{-1}f(k) = f(k - 1)$
$s$	Domínio da frequência contínuo
$z$	Domínio da frequência discreto
$n_\theta$	Número de parâmetros
$ x $	Módulo do número $x$
$\  \cdot \ $	Norma euclidiana
$\  \cdot \ _F$	Norma Frobenius
$J$	Jacobiano
$\hat{J}$	Jacobiano estimado
$u$	Sinal de controle
$y$	Saída de uma planta
$\hat{y}$	Saída de uma planta estimada por uma rede neural
$y_{ref}$	Sinal de referência ( <i>setpoint</i> )
$W_h$	Matriz com os pesos entre a entrada e a camada escondida da rede neural
$W_o$	Matriz com os pesos entre a camada escondida e o neurônio de saída da rede neural
$S$	Função de ativação da camada escondida da rede neural
$b_i$	<i>bias</i> dos neurônios da camada escondida
$b_s$	<i>bias</i> do neurônio da saída
$\tanh$	Função tangente hiperbólica
$\eta$	Taxa de aprendizado da rede neural
$\eta^h$	Taxa de aprendizado dos neurônios da camada escondida
$\eta^o$	Taxa de aprendizado dos neurônios da saída
$r_y$	Autocorrelação linear
$r_{y^2}$	Autocorrelação não-linear



xxii

$T_s$           Tempo de amostragem

# Siglas e Abreviações

AIC	Critério de Informação de Akaike ( <i>Akaike Information Criterion</i> )
ARX	Modelo <u>A</u> uto- <u>R</u> egressivo com entradas e <u>X</u> ógenas
ARMAX	Modelo auto-regressivo de média móvel e entradas exógenas ( <i>AutoRegressive Moving Average model with eXogenous inputs</i> )
BIBO	Entrada limitada e saída limitada ( <i>Bounded Input Bounded Output</i> )
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
CS3000	DCS da Yokogawa
DCS	Sistema de controle digital distribuído ( <i>Distributed Control System</i> )
ERR	Taxa de redução do erro ( <i>Error Reduction Ratio</i> )
FNN	Método dos falsos vizinhos próximos ( <i>False Nearest Neighbors</i> )
IAE	Integral do erro absoluto ( <i>Integral Absolute Error</i> )
IP	Protocolo de Internet ( <i>Internet Protocol</i> )
MDL	Comprimento mínimo de descrição ( <i>Minimum Description Length</i> )
MIMO	Múltiplas Entradas e Múltiplas Saídas ( <i>Multi-Input Multi-Output</i> )
MLP	Rede neural Perceptron de múltiplas camadas ( <i>Multi Layer Perceptron</i> )
MOCP	Laboratório de <u>M</u> odelagem, <u>O</u> timização e <u>C</u> ontrolador de <u>P</u> rocessos
MRAC	Controlador adaptativo por modelo de referência ( <i>Model Reference Adaptive Controller</i> )
NAC	Controle adaptativo neural ( <i>Neural Adaptive Control</i> )
NARX	Modelo não-linear auto-regressivo com entradas exógenas ( <i>Nonlinear AutoRegressive model with eXogenous inputs</i> )
NNARX	Modelo com rede neural auto-regressivo com entradas exógenas ( <i>NNeural Network model with AutoRegressive eXogenous inputs</i> )
NPC	<i>Neural Predictive Control</i>
OLE	<i>Object Linking and Embedding</i>
OPC	<i>OLE for Process Control</i>
PC	<i>Personal Computer</i>
pH	Potencial Hidrogeniônico

PID	Controlador proporcional integral derivativo ( <i>Proportional-Integral Derivative</i> )
RBF	Rede neural com funções de ativação de base radial ( <i>Radial Base Function Neural Network</i> )
RNA	Rede neural
SISO	Uma Entrada e Uma Saída ( <i>Single-Input Single-Output</i> )
STR	Controlador auto-ajustável ( <i>Self-Tuning Regulator</i> )
TCP	Protocolo de controle de transmissão ( <i>Transmission Control Protocol</i> )
TDL	<i>Tapped Delay Line</i>

# Capítulo 1

## Introdução

Esta dissertação diz respeito à utilização de redes neurais para controle, especificamente para este estudo, controle adaptativo. Este é um assunto que, apesar do crescente volume de trabalhos publicados ultimamente, conforme citado por Widrow e Walach (2008), ainda não se vê muitas aplicações na indústria brasileira. Este fato já era esperado visto que nem a aplicação de redes neurais estáticas tem tantas implementações, apesar do crescimento de sua utilização nos últimos anos, como exemplo: Ribeiro (2007) e Takahashi (2006). As técnicas de controle adaptativo têm sido aplicadas principalmente nas áreas da aviação e da robótica (Nardi, 2000; Hageman et al., 2003; Cox et al., 1996; Popescu et al., 2001; Brinker e Wise, 1996; Bugajski e Enns, 1992; Enns et al., 1994; Lane e Stengel, 1988; Lee e Hedrick, 1994; Singh e Steinberg, 1996).

Este trabalho foi inspirado nos artigos (Maitelli e Filho, 2003a) e (Maitelli e Filho, 2003b). O primeiro apresenta as informações para a implementação da técnica denominada **Controle Neural Adaptativo Híbrido Indireto**. O segundo apresenta um estudo de estabilidade, baseado no método direto de Lyapunov, e robustez da técnica.

### 1.1 Uma breve revisão histórica

As pesquisas com controladores adaptativos vêm se desenvolvendo desde a década de 50, motivadas principalmente pelo desafio do projeto de pilotos automáticos para a aviação. Aviões de alto desempenho sofrem mudanças consideráveis em suas dinâmicas quando eles mudam de um ponto de operação para outro, o que impossibilita a aplicação de controladores de ganho constante, por isso a necessidade da implementação de controladores adaptativos (Ioannou e

Fidan, 2006). Whitaker foi um dos pioneiros na tentativa de resolver este problema (Whitaker et al., 1958; Osburn et al., 1961) *apud* (Nardi, 2000; Ioannou e Fidan, 2006). Outra técnica como a Alocação de pólos adaptativa foi sugerida em (Kalman, 1958) *apud* (Ioannou e Fidan, 2006). Apesar de muitos esforços e muitas pesquisas, o nível de conhecimento sobre o assunto e a inexistência de provas quanto a estabilidade e robustez das técnicas propostas resultaram na diminuição do interesse em controle adaptativo naquele período.

Apesar dos insucessos da década anterior, a década de 60, conforme Ioannou e Fidan (2006), foi rotulada como a mais importante no avanço da teoria de controle, em especial o controle adaptativo, com o surgimento das técnicas de espaços de estados e a teoria de estabilidade baseada nas funções de Lyapunov. Estes avanços melhoraram o entendimento das técnicas de controle adaptativo e renovaram o interesse dos pesquisadores durante os anos 70. Outro ponto que ajudou e motivou as pesquisas durante a década de 70 foi o avanço no desenvolvimento de computadores e da eletrônica, possibilitando a implementação de controladores complexos, entre eles, os controladores adaptativos.

Durante a década de 70, esquemas MRAC, do inglês *Model Reference Adaptive Control*, foram desenvolvidos baseados nas funções de Lyapunov. Houve o desenvolvimento de uma grande variedade de controladores MRAC com provas de estabilidade bem estabelecidas. Em paralelo surgiam novas técnicas com referência no tempo discreto (Ioannou e Fidan, 2006). Porém, apesar de todo o sucesso apresentado em várias publicações da época, (Egardt, 1979) *apud* Ioannou e Fidan (2006) apontou que várias técnicas propostas durante a década de 70 entravam em instabilidade na presença de pequenos distúrbios e questionou a aplicabilidade destas.

Em meados da década de 80, uma série de modificações e melhorias foram propostas, iniciando uma nova era no desenvolvimento da área, os **controladores adaptativos robustos**. Um controlador adaptativo é definido como sendo robusto se garantir o sinal de saída dentro de uma determinada faixa na presença de uma classe "aceitável" de dinâmicas não modeladas e de distúrbios, também dentro de um certo limite. Outro requisito é que os limites para o erro de desempenho do controlador estejam na mesma ordem de grandeza do erro de modelagem (Ioannou e Fidan, 2006). Para o tempo discreto, Praly foi o primeiro a estabelecer um estudo da estabilidade global na presença de dinâmicas não modeladas e distúrbios (Praly, 1984) *apud* (Ioannou e Fidan, 2006).

No final da década de 80 e início da década de 90 os esforços começaram a ser direcionados para o controle de plantas não-lineares. A partir deste ponto foram iniciadas as pesquisas para aproveitamento da característica de aproximador universal das redes neurais nas técnicas de controle adaptativo (Narendra e Parthasarathy, 1990).

## 1.2 Motivação

Nas indústrias ainda é grande o número de malhas de controle funcionando abaixo do esperado. Isto ocorre devido ao fato do controlador não estar sintonizado da forma adequada, ou ainda, pelo fato do controlador, mesmo que bem projetado, não ser do tipo adequado. Em determinados processos com alto grau de não-linearidade, um controlador PID não responde satisfatoriamente em todas as faixas de operação, sendo necessário lançarmos mão de técnicas de controle avançadas, sendo uma delas o controle adaptativo neural (Vandoren, 2003).

Em tempos de crise, nas indústrias, os engenheiros são solicitados a reduzir custos e procurar oportunidades de melhorias na qualidade de produtos e processos. Assumindo esta função, os engenheiros das indústrias atualmente devem se perguntar: provavelmente a especificação de um equipamento foi baseada na utilização de controladores convencionais, será que mesmo onde o PID está atendendo as especificações, existe espaço para melhorar? Este é mais um exemplo de que crises não geram apenas problemas, mas também oportunidades.

Com este contexto e aproveitando esta oportunidade, a procura por uma técnica de controle avançada que pudesse melhorar o desempenho de algumas malhas ou até resolver os problemas de outras foi feita. A técnica proposta por Maitelli e Filho (2003a) é aplicável em sistemas não-lineares, como são os sistemas reais, e pelo menos inicialmente, pareceu ser de simples implementação, por isso a escolha por esta técnica. Outra vantagem desta escolha é que esta já possuía um estudo de sua estabilidade e robustez apresentado em Maitelli e Filho (2003b).

Outro ponto que motivou este estudo foi constatar, durante o levantamento dos trabalhos realizados com a técnica proposta, que eles limitavam-se à aplicação em sistemas teóricos simulados ou em plantas piloto (Filho et al., 2008; Lopes et al., 2006). Muitos outros trabalhos com controle adaptativo utilizando redes neurais estão na literatura, conforme citado em Muniz (2004), porém poucos deles apresentam resultados na indústria (Ramirez-Beltran e Jackson, 1999), e este número diminui para o contexto nacional. Pretende-se com este trabalho testar e apresentar seu comportamento e eficiência numa planta real, industrial, com todas as interferências e distúrbios característicos deste tipo de aplicação.

## 1.3 Objetivos

Os objetivos deste trabalho são:

1. investigar o comportamento e eficiência da técnica de controle neural adaptativa híbrida indireta numa planta real, industrial;

2. como consequência do primeiro, enriquecer a literatura sobre o assunto com sua aplicação no ambiente industrial, visto que não foram encontrados registros dessa natureza;
3. explorar e investigar os resultados de variações no número de neurônios, no tamanho da janela de treinamento e no número de atrasos de entrada e saída utilizados na rede neural, visto que não foi encontrado nenhum trabalho que apresente este estudo.

## 1.4 Organização do texto

Esta dissertação está organizada em sete capítulos da seguinte forma:

**Capítulo 2: Controle Adaptativo.** Este capítulo apresenta os conceitos básicos, as classificações possíveis e as principais estratégias de controle adaptativo para aplicação com redes neurais.

**Capítulo 3: Redes Neurais para Controle.** Neste capítulo são apresentados o conceito e as formas de aplicação das redes neurais recorrentes para controle. A base teórica exposta nos capítulos 2 e 3 dão o conhecimento básico para o entendimento do esquema de controle implementado neste trabalho.

**Capítulo 4: O Esquema de Controle.** Este capítulo apresenta a descrição e os cálculos para cada etapa da estratégia e o algoritmo para implementação do esquema de controle.

**Capítulo 5: Aplicações do Controle em Simulações e numa Planta Piloto.** Neste capítulo, são apresentados o desenvolvimento e os resultados da implementação do esquema de controle em um modelo e em uma planta piloto de um sistema de neutralização de  $pH$ . Aproveitando a disponibilidade do modelo, foram realizados os testes da variação do número de neurônios, do número de atrasos de entrada e saída na entrada da rede neural e do tamanho de janela de treinamento. Os resultados destes testes são apresentados neste capítulo.

**Capítulo 6: Aplicação do Controle em Uma Planta Industrial.** Neste capítulo são apresentados o processo industrial onde o esquema de controle foi implementado e os resultados desta implementação.

**Capítulo 7: Considerações finais.** Este capítulo apresenta as conclusões a respeito do trabalho realizado e sugestões para trabalhos futuros.

# Capítulo 2

## Controle Adaptativo

### 2.1 Introdução

O controle de processos em malha fechada, que é o tipo mais comum na indústria, é o mecanismo que automaticamente regula o sinal de controle, como a abertura de uma válvula, a corrente de um motor dentre outras, na tentativa de manter sua saída próximo ao ponto desejado (Ogata, 2003). Isto é o que os controladores PID tentam realizar na indústria, porém, em alguns casos, o processo tem alto grau de não-linearidade ou tem frequentes variações do ambiente, que acarretam num desempenho abaixo do esperado para este tipo de controlador.

Os controladores PID são baratos e atualmente muito disseminados e de fácil implementação. A sintonia também é de fácil execução, podendo em muitas vezes ser realizada com alguns testes empíricos. Porém, uma vez sintonizado, este só pode controlar o processo original no ponto de operação em que foi ajustado. Se ocorrerem variações consideráveis no comportamento do sistema ou dos distúrbios, este pode vir a falhar levando o sistema à instabilidade (Vandoren, 2003).

As variações na dinâmica dos sistemas são decorrentes da deterioração de componentes ao longo do tempo, variações na massa, pressão atmosférica (aviões) dentre outras. Em sistemas de malha fechada, pequenas variações são atenuadas (Ogata, 2003). Para os casos em que as variações no ambiente sejam frequentes e/ou existe alto grau de não-linearidade, se faz necessário um sistema de controle com capacidade de se adaptar ao novo ambiente (sistema + distúrbios), e corrigir a atuação de controle automaticamente.

Mas o que significa "adaptar"? Fora de um contexto específico, intuitivamente responde-se que



"adaptar" seria mudar o comportamento conforme novas circunstâncias do ambiente. Trazendo essa idéia para aplicação na definição de controle adaptativo, conclui-se que um controlador é adaptativo quando é capaz de mudar seu comportamento na ocorrência de mudanças na dinâmica dos processos e/ou nos distúrbios. Segundo Astrom e Wittenmark (1994), muitos questionaram esta definição: Se qualquer controle em malha fechada é projetado para ficar imune às interferências de alterações na dinâmica do processo e de distúrbios, então qual é a diferença de um controlador em malha fechada convencional e de um controlador adaptativo? Houve durante os anos muitas tentativas de se elaborar uma definição formal para o termo "controle adaptativo", mas sem sucesso. A primeira tentativa, num simpósio em 1961, definiu-se controle adaptativo como sendo qualquer sistema físico que foi projetado com um ponto de vista adaptativo. O consenso era que um controlador em malha fechada com ganho constante não é adaptativo (Astrom e Wittenmark, 1994).

A primeira definição parece clara, pois um controlador malha fechada comum, por exemplo um PID, altera a saída e não os seus parâmetros. O problema, ao que parece, está no entendimento na parte que diz "... mudar seu comportamento...". Mudar seu comportamento pode ser entendido como o controlador alterar a sua reação ou alterar sua forma de reagir. O conceito fica claro quando é visto o exemplo para um controlador PID. Sabe-se que quando este é sintonizado no *startup* de uma planta, se as condições do processo e dos distúrbios se mantêm inalteradas, nenhum trabalho extra é necessário, mas por outro lado, se há modificações no processo e/ou nos distúrbios, uma nova sintonia de seus parâmetro é necessária, o que significa que ele não é um controlador adaptativo (Vandoren, 2003).

Desta forma, para este trabalho foi utilizada a seguinte definição: Controle adaptativo é o controle capaz de mudar seu comportamento, sua forma de reagir, suas características, seus parâmetros, na ocorrência de mudanças na dinâmica do processo e/ou nos distúrbios.

## **2.2 Vantagens e Desvantagens de um Sistema de Controle Adaptativo**

### **2.2.1 Vantagens**

Quando o sistema apresenta alto grau de não-linearidade ou variações frequentes no ambiente, ficam evidentes as vantagens do controle adaptativo. O caso de alto grau de não-linearidade pode ser resolvido com a técnica chamada "*gain scheduling*", que consiste em projetar parâmetros específicos para cada faixa de operação. A desvantagem desta técnica é que para cada faixa de operação deverá ser realizado um projeto independente. Para o segundo caso não existe má-

ica, com a variação frequente do ambiente, o controlador convencional deve ser resintonizado, o que acarreta a presença frequente de um especialista para ajustes do controlador. Mais uma vez fica evidente a vantagem do sistema de controle adaptativo, que responde as variações do ambiente e se ajusta automaticamente à nova condição.

Controladores adaptativos geralmente apresentam melhor eficiência se comparados aos controladores de ganho constante. Eles têm a tendência de eliminar erros mais rapidamente e, conseqüentemente, manter a saída próxima ao desejado por mais tempo (Vandoren, 2003).

### 2.2.2 Desvantagens

Tudo tem seu preço. Apesar das vantagens comentadas no item anterior, os controladores adaptativos são mais complexos que os tradicionais PID. Na ocorrência de falha num controlador adaptativo é necessária a presença de um especialista, não seria qualquer pessoa capaz de atender o sistema. Porém, algumas ferramentas comerciais têm a característica de abstrair o controlador, de forma que quem o utiliza não necessita do total conhecimento do seu funcionamento para operá-lo. Outro ponto negativo para sua utilização é a desconfiança dos operadores. Os engenheiros de controle até confiam e incentivam sua utilização, mas o problema é a desconfiança do pessoal de operação (Vandoren, 2003). A tendência é que na ocorrência de uma falha num sistema de controle, mesmo que a falha não seja do controlador adaptativo, ele será sempre o primeiro suspeito.

## 2.3 Classificações para Controladores Adaptativos

De uma forma geral, os esquemas de controle adaptativo executam a seguinte sequência de ações, que também é demonstrada na figura 2.1:

1. Coletar os dados de entrada e saída da planta que se deseja controlar;
2. Definir os parâmetros para ajuste do controlador a partir de uma determinada estratégia;
3. Calcular a nova ação de controle com base nos parâmetros definidos na etapa anterior, na sua saída real e na sua saída desejada;
4. Atuar na entrada da planta com objetivo de manter a saída próxima do desejado.

A seguir são apresentadas as classificações utilizadas na diferenciação entre os diversos esquemas de controle adaptativo.

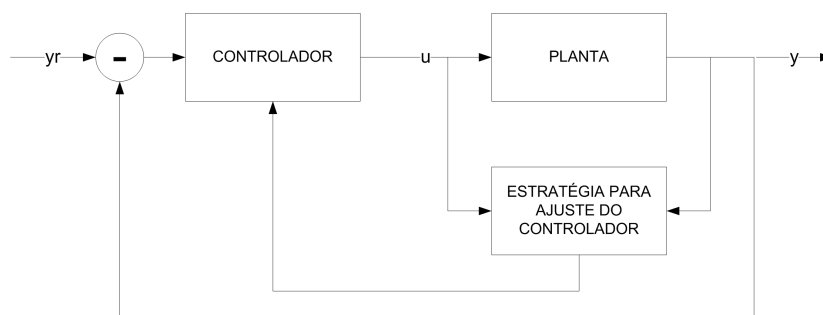


Figura 2.1: Esquema Geral para Controladores Adaptativos

### 2.3.1 Controle Adaptativo Baseado em Identificador

São classificados como controladores adaptativos baseados em identificador aqueles esquemas que possuem na sua estrutura, na etapa de definição dos parâmetros para ajuste do controlador, um bloco com a função de estimar, de forma *online*, parâmetros da planta inicialmente não conhecidos.

Dentro da classe dos esquemas de controle adaptativo baseados em identificador, pode-se ainda classificá-los como *Diretos* e *Indiretos*.

#### 2.3.1.1 Controle Adaptativo Direto

São classificados como esquemas de *controle adaptativo direto* aqueles em que o estimador de parâmetros fornece diretamente os parâmetros necessários para o controlador, para a lei de controle, sem cálculos intermediários, conforme mostra a figura 2.2.

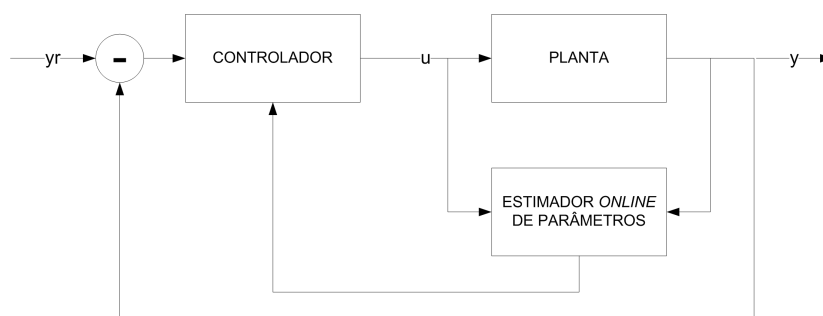


Figura 2.2: Estrutura para o Controle Adaptativo Direto

### 2.3.1.2 Controle Adaptativo Indireto

São classificados como esquemas de *controle adaptativo indireto* aqueles em que o estimador de parâmetros fornece parâmetros intermediários. Estes passam ainda por cálculos e são convertidos nas variáveis requeridas pelo controlador, conforme mostra a figura 2.3.

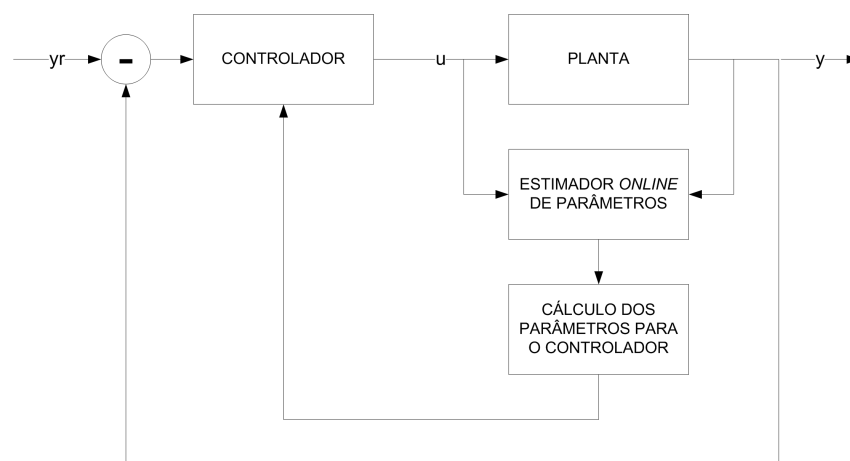


Figura 2.3: Estrutura para o Controle Adaptativo Indireto

Alguns autores, como por exemplo (Ioannou e Fidan, 2006; Astrom e Wittenmark, 1994), diferenciam a classificação *direta* para a *indireta* avaliando se a estratégia de controle utiliza os parâmetros do modelo estimado diretamente no controlador ou se existem cálculos intermediários. Outros autores, como por exemplo (Carvalho e Prado, 2008; Norgaard, 2000) se baseiam na existência ou não do identificador. Neste trabalho, conforme visto nas definições das seções 2.3.1.1 e 2.3.1.2, foi utilizada a definição adotada por Astrom e Wittenmark (1994) e Ioannou e Fidan (2006). A definição adotada pelos outros autores confunde com a definição de controle baseado em identificador ou não-baseado em identificador, na verdade são duas classificações diferentes.

### 2.3.2 Controle Adaptativo Não Baseado em Identificador

São classificados como esquemas de *controle adaptativo não baseado em identificador* aqueles que, no lugar do estimador de parâmetros *online*, apresentam uma tabela de parâmetros ou controladores pré-ajustados para cada faixa de operação da planta e uma lógica para seleção dos parâmetros desta tabela. A técnica *gain scheduling* é um exemplo para este tipo de esquema. Para cada faixa de operação existe um registro numa tabela de parâmetros para ajuste de um controlador convencional. Acompanha esta tabela uma lógica que, baseada na entrada, saída e até outras informações auxiliares, determina a faixa de operação da planta, seleciona os parâ-

metros na tabela e seta a nova condição do controlador, ou seja, existem vários controladores lineares selecionáveis. Alguns pesquisadores não a classificam como adaptativa, pois ela não realiza nenhum ajuste *online*, apenas seleção de parâmetros pré-estabelecidos. Esta é uma estratégia muito utilizada em controle de vôo, apesar de suas limitações (Ioannou e Fidan, 2006). Sua indicação de utilização é para sistemas com variações previsíveis em sua dinâmica (Astrom e Wittenmark, 1994). Seu esquema é mostrado na figura 2.4.

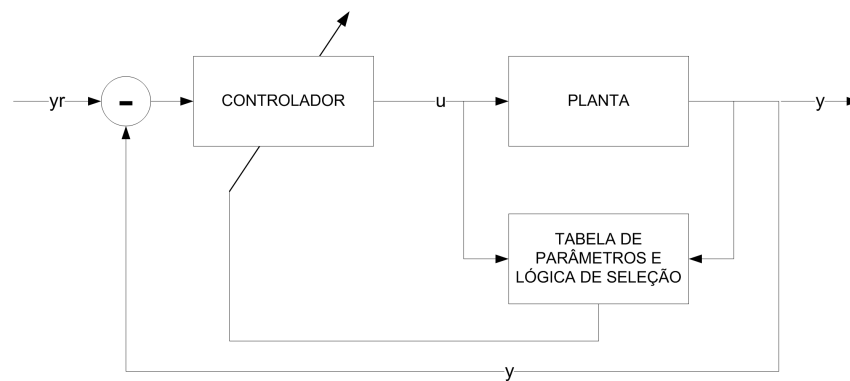


Figura 2.4: Estratégia *Gain Scheduling*

### 2.3.3 Controle Utilizando Redes Neurais

Os esquemas de controle adaptativo podem ainda fazer uso de redes neurais em sua estrutura. Dependendo de onde é utilizada a rede neural na estrutura do esquema de controle, este pode ser classificado como *híbrido* ou *não-híbrido*.

#### 2.3.3.1 Controle Neural Adaptativo Híbrido

São classificados como esquemas de *controle neural adaptativo híbrido* aqueles que fazem uso de um controlador convencional e a rede neural é utilizada apenas no bloco de identificação, conforme mostra a figura 2.5.

#### 2.3.3.2 Controle Neural Adaptativo Não-Híbrido

São classificados como esquemas de *controle neural adaptativo não-híbrido* aqueles que apresentam na sua estrutura a utilização de redes neurais tanto no bloco de identificação quanto no bloco do controlador, conforme mostra a figura 2.6.

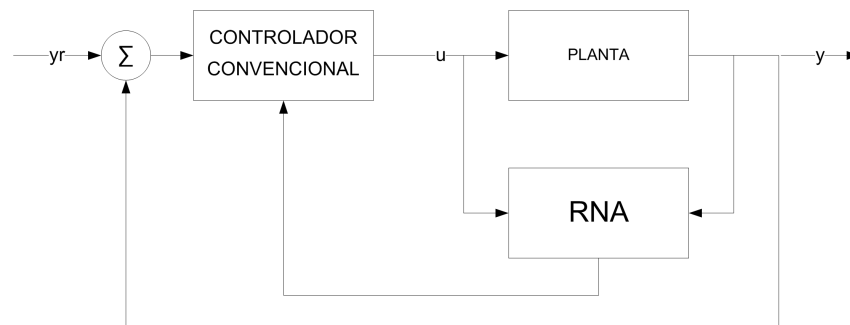


Figura 2.5: Esquema de Controle Adaptativo Híbrido

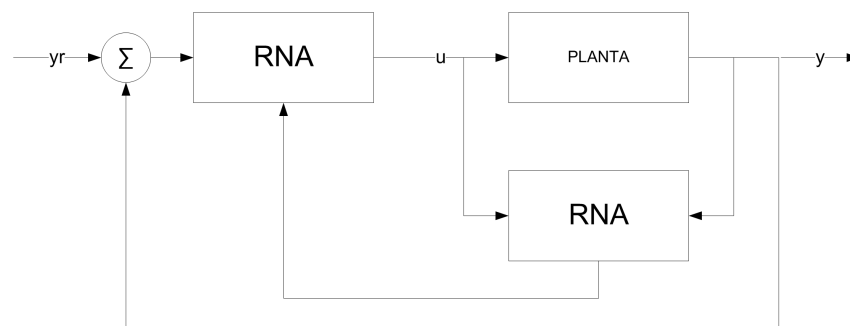


Figura 2.6: Esquema de Controle Adaptativo Não-Híbrido

## 2.4 Algumas Estratégias de Controle Adaptativo

Nesta seção são brevemente apresentadas duas estratégias, as mais difundidas: *Controlador Adaptativo por Modelo de Referência* e *Controlador Auto Ajustável*.

### 2.4.1 Controle Adaptativo por Modelo de Referência

O controle adaptativo por modelo de referência, traduzido do inglês *Model Reference Adaptive Control*, foi originalmente utilizado em controle de vôo e é uma das técnicas mais utilizadas. Seu esquema pode ser visto na figura 2.7.

O modelo de referência é escolhido de forma que sua saída seja seguida pela saída da planta. Este esquema pode ainda ser classificado como *direto* ou *indireto*. Esquemas MRAC possuem uma malha entre o processo e o controlador e outra malha envolvendo o controlador, o processo e a estratégia de ajuste dos parâmetros do controlador. Os parâmetros são ajustados com base na diferença entre a saída do modelo e a saída da planta. O ajuste de parâmetros, para esquemas MRAC, pode ser realizado de duas formas: pelo método do gradiente ou ainda aplicando uma

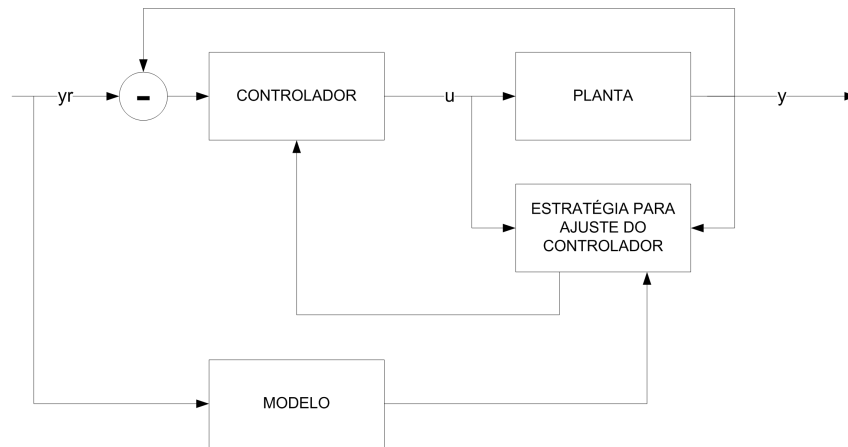


Figura 2.7: Esquema MRAC

teoria de estabilidade (Astrom e Wittenmark, 1994).

#### 2.4.2 Controle Auto Ajustável (STR)

O controle auto ajustável, traduzido do inglês *Self Tunning Regulator* (STR), coleta os dados de entrada e saída da planta na etapa de identificação, novos parâmetros são ajustados e, com base nestes, são realizados cálculos que geram informação para o ajuste do controlador. Da descrição acima e conforme a figura 2.8, pode-se concluir que a estratégia STR é do tipo *baseada em identificador e indireta*. Se ainda fizer uso de redes neurais, classifica-se ainda como *híbrida* ou *não-híbrida*.

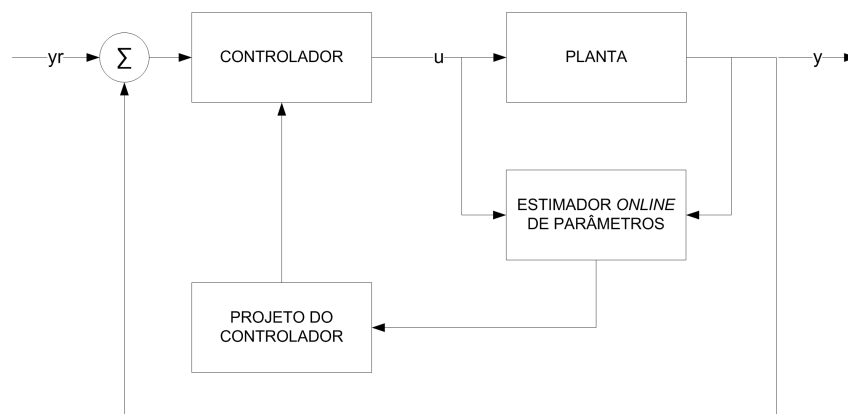


Figura 2.8: Esquema STR

A estratégia de controle implementada neste trabalho é do tipo STR.

# Capítulo 3

## Redes Neurais para Controle

### 3.1 Introdução

As redes neurais do tipo MLP, do inglês *Multi-Layer Perceptron*, com treinamento supervisionado têm sido muito utilizadas em sistemas de controle, principalmente, para identificação de sistemas, mas também fazendo o papel do controlador (Jain e Fanelli, 2000).

### 3.2 Identificação de Sistemas Dinâmicos Usando Redes Neurais

Identificar um sistema dinâmico significa gerar um modelo, uma representação matemática, com base em uma série de medidas deste. Para executar este trabalho as redes neurais são utilizadas em sua estrutura recorrente. Apesar de ter sido comentado anteriormente que as redes neurais em controle de sistemas dinâmicos possam ser utilizadas tanto na etapa de identificação quanto no lugar do controlador, o foco deste trabalho está em sua utilização na etapa de identificação.

Um sistema dinâmico é aquele que permite descrever sua saída atual com base em suas entradas e saídas passadas, sua memória. Então, um modelo identificado de um sistema dinâmico poderia ser descrito, por exemplo, para o caso linear discreto, da seguinte forma:

$$y(k + 1) = a_1y(k) + a_2y(k - 1) + a_3y(k - 2) + b_1u(k) + b_2u(k - 1) + e(k + 1) \quad (3.1)$$



O erro de modelagem pode ser escrito da seguinte forma:

$$e(k+1) = y(k+1) - \hat{y}(k+1) \quad (3.2)$$

Sendo a saída estimada dada por:

$$\hat{y}(k+1) = a_1 y(k) + a_2 y(k-1) + a_3 y(k-2) + b_1 u(k) + b_2 u(k-1) \quad (3.3)$$

Esta representação poderia ser identificada pela seguinte rede neural, com cinco entradas e apenas um neurônio com função de ativação-linear.




Figura 3.1: Exemplo de Rede Neural para Identificação

A figura 3.1 apresenta um exemplo de rede neural recorrente utilizada na identificação, porém numa configuração muito simples e linear. Por definição as redes neurais recorrentes são redes com realimentação de uma ou mais saídas, globais ou intermediárias. O caso de realimentação de uma saída intermediária pode ocorrer em redes com uma ou mais camadas escondidas, onde a saída de um neurônio da camada escondida é realimentada na rede.

Um caso geral de rede neural recorrente, com realimentação global é mostrado na figura 3.2.

As redes neurais recorrentes utilizadas para identificação, do tipo *Input-Output*, realizam a realimentação de valores passados da entrada e da saída da planta. O número de entradas e saídas passadas, ou seja, sua ordem, depende do projeto. Seu caso geral pode ser visto na figura 3.3.

O esquema NNARX mostrado na figura 3.3 é estável no sentido BIBO (*Bounded Input Bounded Output*) devido a não possuir realimentação da saída estimada e por este motivo é o modelo preferido quando o sistema a ser modelado é determinístico (Norgaard et al., 2001) *apud*

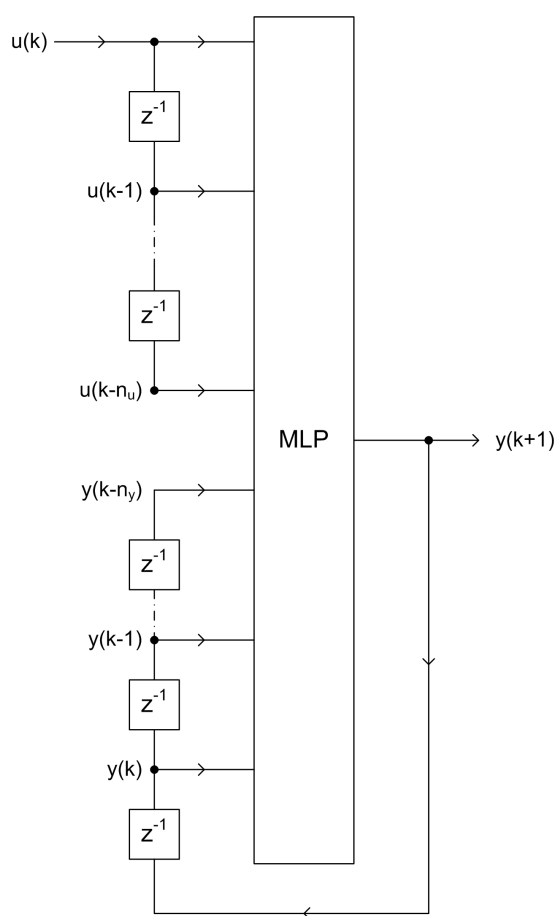


Figura 3.2: Esquema Geral NNARX - *Neural Network Autoregressive with exogeneous inputs*

(Maitelli e Filho, 2003a). Este é o esquema utilizado neste trabalho.

Outro fator que deve ser observado no projeto de redes neurais para identificação de sistemas não-lineares é a complexidade da rede neural, a determinação de quantos neurônios serão utilizados em sua(s) camada(s) escondida(s). As redes MLP têm a capacidade de identificar sistemas não-lineares e elas próprias também são altamente não-lineares, conseqüentemente, sua sobreparametrização pode gerar dinâmicas espúrias (Aguirre e Billings, 1995). As redes neurais MLP, com camada(s) escondida(s) e funções de ativação não-lineares, utilizadas na identificação de sistemas não-lineares, apresentam menor capacidade de generalização na medida em que se aumenta o número de neurônios de sua(s) camada(s) escondida(s), este problema é conhecido como o dilema da polarização e da variância (Gemam et al., 1992) *apud* (Amaral, 2001). Elas se tornam mais flexíveis e, conseqüentemente, capazes de aprender o ruído, perdendo sua capacidade de generalização (Haykin, 2001).




Figura 3.3: Esquema NNARX para Identificação

Da mesma forma que o número de neurônios da camada escondida, outros fatores que podem influenciar na capacidade de generalização da rede são o valor limite para o erro de treinamento (erro meta) e o número máximo de iterações para cada etapa de treinamento. Quanto mais se treina e quanto mais se tenta aproximar da função original, se o número de neurônios permitir, mais se perde a capacidade de generalização. Por outro lado, se o número de neurônios, o número de iterações e o erro meta estiverem aquém do ideal, pode ocorrer o efeito contrário, a rede não aprende o ruído, mas também não aprende a dinâmica do sistema. Estes fenômenos são conhecidos como *overfitting* e *underfitting* (Haykin, 2001). Algumas estratégias de poda, citadas na literatura, no sentido de se evitar a sobreparametrização, são citadas em (Costa et al., 2002; Reed, 1993; Henrique et al., 2000; Hassibi et al., 1992; Hagiwara, 1990; Hinton, 1989) *apud* (Amaral, 2001). Outros autores ainda utilizam diagramas de bifurcação como critério de validação de redes treinadas (Corrêa et al., 1999) *apud* (Amaral, 2001) e a combinação de

modelos semi-físicos com redes neurais (Forssell e Linkskop, 1997) *apud* (Amaral, 2001).

A poda, ou *pruning* em Inglês, é o procedimento de eliminar conexões sinápticas e nós que pouco influenciam na estrutura. Inicia-se a rede com sobreparametrização, com número excessivo de neurônios. Durante o treinamento seus parâmetros são avaliados e, no final, a rede treinada é composta apenas dos pesos e nós relevantes, parte deles é "podada" (Braga et al., 2000).

Para a determinação da ordem do modelo existem alguns métodos como por exemplo o *Akaike's Information Criterion* (AIC), *Minimum Description Length* (MDL) e *Error Reduction Ratio* (ERR). Para este trabalho foram realizados experimentos com o método *False Nearest Neighbor* (FNN) (Rhodes e Morari, 1998). Este último foi escolhido devido à sua independência da estrutura do modelo, que neste caso é definida pela própria rede neural. Outro fator que influenciou na sua escolha foi por ser uma metodologia aplicável tanto para sistemas lineares quanto para sistemas não-lineares. Estas características, a princípio, indicam este método ser adequado para o problema de definição de ordem de identificadores neurais.

### 3.2.1 False Nearest Neighbor (FNN)

A maioria dos métodos de identificação baseados nos dados de entrada e saída de um sistema dinâmico não-linear assumem que a sua estrutura já seja conhecida, ou seja, assumem que já se realizou um estudo prévio onde foram determinados a ordem e os termos candidatos para o processo de identificação (Feil et al., 2003). Para o caso de identificação com o uso de redes neurais, o problema se limita na escolha da ordem, a identificação dos relacionamentos entre os regressores na montagem dos termos é feita pela rede neural.

A escolha da ordem de modelos em sistemas dinâmicos lineares possui literatura vasta. Muitos critérios de informação foram propostos na busca da ordem de modelos, entre eles: AIC (*Akaike's Information Criterion*), FPE (*Final Prediction Error*) e MDL (*Minimum Description Length*), sendo este último o mais consistente (Feil et al., 2003).

Para o caso de sistemas não-lineares existem alguns trabalhos na busca da determinação da ordem e estrutura, porém a maioria dos métodos está amarrada a um determinado tipo de representação (Feil et al., 2003). Para evitar este problema, a técnica baseada na identificação de *falsos vizinhos* (FNN - *False Nearest Neighbors*) foi escolhida. A determinação da ordem para o modelo é feita sem qualquer dependência da representação que será utilizada (Feil et al., 2003).

O método FNN consiste na avaliação da geometria dos dados de entrada e saída coletados do

sistema. Se há informação suficiente no vetor de regressão para prever a saída futura, então para quaisquer dois vetores de regressão, que são próximos no espaço de regressão, as saídas correspondentes também estão próximas (Rhodes e Morari, 1998).

A seguir são apresentados os passos para implementação do algoritmo FNN:

1. Dado o ponto,

$$r_{l,m}(k) = [y(k - \tau), \dots, y(k - l\tau), u(k - \tau), \dots, u(k - m\tau)] \quad (3.4)$$

encontre o ponto  $r_{l,m}(j)$  nos dados onde a seguinte distância, no sentido *euclidiano*, é minimizada:

$$D = \|r_{l,m}(k) - r_{l,m}(j)\| \quad (3.5)$$

2. Determine se a seguinte expressão é verdadeira ou falsa:

$$\frac{|y(k) - y(j)|}{\|r_{l,m}(k) - r_{l,m}(j)\|} \leq R \quad (3.6)$$

sendo  $R$  um valor pré-determinado. Se a expressão for verdadeira, este é um vizinho verdadeiro. Se a expressão for falsa, foi identificado um *falso vizinho*.

3. Continue para todos os  $k$  elementos no conjunto de dados. Após verificado todos os pontos, calcule a porcentagem de falsos vizinhos.
4. Continue o algoritmo aumentando  $l$  e  $m$  até a porcentagem de falsos vizinhos cair a zero ou para um valor relativamente pequeno.

A determinação de  $R$  pode ser feita por tentativa e erro ou ainda através do maior valor do Jacobiano, conforme proposto por Rhodes e Morari (1998). Para o presente trabalho foi realizada a determinação de  $R$  por tentativa e erro, ou seja, o procedimento citado anteriormente é repetido para vários valores de  $R$ . Segundo Rhodes e Morari (1998), a partir de um determinado ponto, aumentando-se o valor de  $R$ , a distribuição da porcentagem de falsos vizinhos permanece praticamente constante. A partir deste ponto, a avaliação da estimativa da ordem do modelo, conforme cita o último item do procedimento, é válida.

### 3.2.2 Escolha do tempo de amostragem

A definição do tempo de amostragem apropriado na identificação e controle de um sistema é de suma importância. Tempos de amostragem diferentes afetam o desempenho de modelos

identificados (Aguirre, 2004).

Para esta etapa do trabalho foi seguido um procedimento prático proposto por (Aguirre, 2004). A idéia é realizar uma superamostragem do sinal de saída do sistema e analisar suas autocovariâncias linear  $r_y(\tau)$  e não-linear  $r_{y^2}(\tau)$ .

$$r_y(\tau) = E[(y(k) - \overline{y(k)}) \cdot (y(k - \tau) - \overline{y(k)})] \quad (3.7)$$

$$r_{y^2}(\tau) = E[(y^2(k) - \overline{y^2(k)}) \cdot (y^2(k - \tau) - \overline{y^2(k)})] \quad (3.8)$$

sendo  $E(\cdot)$  a esperança matemática.

Avaliando os gráficos resultantes desta análise, deve ser encontrada para a autocovariância linear e para a não-linear os valores de atrasos para os seus primeiros mínimos ( $\tau_y$  e  $\tau_{y^2}$ ). O menor dos mínimos  $\tau_m$  é utilizado na expressão (3.10) na determinação da faixa de taxas de amostragem viável.

$$\tau_m = \min \tau_y, \tau_{y^2} \quad (3.9)$$

$$\frac{\tau_m}{20} < T_s < \frac{\tau_m}{10} \quad (3.10)$$

Para este trabalho, o sistema utilizado para os testes de avaliação da ordem e do tempo de amostragem foi o modelo da planta de neutralização de  $pH$  simulado no Matlab. Foi escolhido este sistema devido à sua disponibilidade e velocidade para obtenção de resultados. Os parâmetros avaliados para o modelo da planta de neutralização de  $pH$  foram depois utilizados como referência nas simulações com a planta piloto.

Para a planta industrial, a definição do tempo de amostragem e a estimação da ordem da rede neural utilizada no esquema de controle foi feita com base na avaliação dos parâmetros e dos dados da malha de controle original.



# Capítulo 4

## A Estratégia de Controle

### 4.1 Introdução

Os controladores baseados em redes neurais têm se apresentado como uma abordagem muito atrativa em controle adaptativo devido a algumas características das redes neurais: a capacidade de aprendizado e a de aproximação universal.

Apesar das vantagens da aplicação de redes neurais para esquemas de controle adaptativo, o treinamento de redes neurais é uma tarefa muito custosa e dependendo da complexidade e velocidade do treinamento, a utilização de controladores adaptativos baseados em redes neurais é inviabilizada para alguns casos onde o tempo necessário para a etapa de treinamento da rede neural é maior do que período de amostragem.

Mas alguns fatores que têm contribuído nos últimos anos, principalmente, a partir do início do século XXI, são o grande e rápido avanço na tecnologia de microprocessadores e de protocolos de comunicação. Esses últimos avanços, combinados com a popularização dos computadores devido à queda de preços desses itens, permitiram que aplicações de controle em tempo real fossem implementadas até em computadores pessoais. Atualmente os pesquisadores têm acesso à máquinas mais velozes e que, conseqüentemente, propiciam a realização de testes e implementações com controle adaptativo neural. O progresso na área dos microprocessadores tem contribuído para a diminuição do leque de aplicações inviáveis.



## 4.2 O Esquema de Controle

O esquema de controle apresentado, um caso especial da estratégia apresentada na Seção 2.4.2, foi originalmente proposto em Maitelli e Filho (2003a) e tem construção similar ao que foi proposto em Adetona et al. (2001). As duas propostas se diferenciam basicamente pela forma com que chegaram na lei de controle e no tipo de rede neural utilizada. No trabalho de Adetona foi utilizada uma rede neural do tipo RBF (*Radial Basis Function*), enquanto que no trabalho de Maitelli foi utilizada uma rede neural do tipo MLP (*Multi Layer Perceptron*) (Maitelli e Filho, 2003a).

O esquema consiste basicamente no uso de uma rede neural, um *neuro-emulador*, para identificação da planta que se deseja controlar. Após o treinamento da rede e identificação de um modelo da planta, na região treinada, são extraídos os pesos desta com o objetivo de se calcular o *Jacobiano*. Utiliza-se então o *Jacobiano* estimado  $\hat{J}$ , na lei de controle proposta para o cálculo da nova ação de controle com o objetivo de manter a saída da planta próxima da saída desejada. O diagrama esquemático desta estratégia é apresentado na figura 4.1.

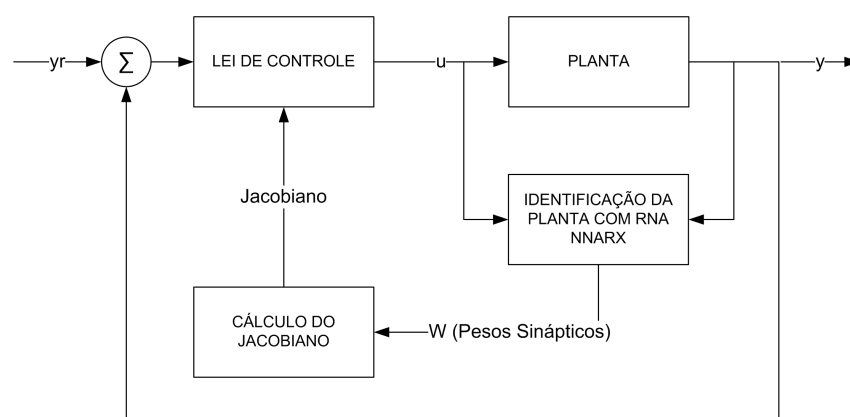


Figura 4.1: Esquema de controle neural adaptativo utilizado

O esquema apresentado foi utilizado para o caso SISO (*Single Input Single Output*). A rede neural utilizada foi configurada com uma camada escondida. Os neurônios da camada escondida foram configurados com função de ativação tangente hiperbólica e o neurônio da saída com função de ativação-linear. Esta configuração tem a característica de ser um aproximador universal para funções contínuas, podendo ser aplicada tanto para sistemas lineares quanto para sistemas não-lineares (Haykin, 2001).

O esquema da figura 4.2 é do tipo série-paralelo, pois não apresenta realimentação da saída

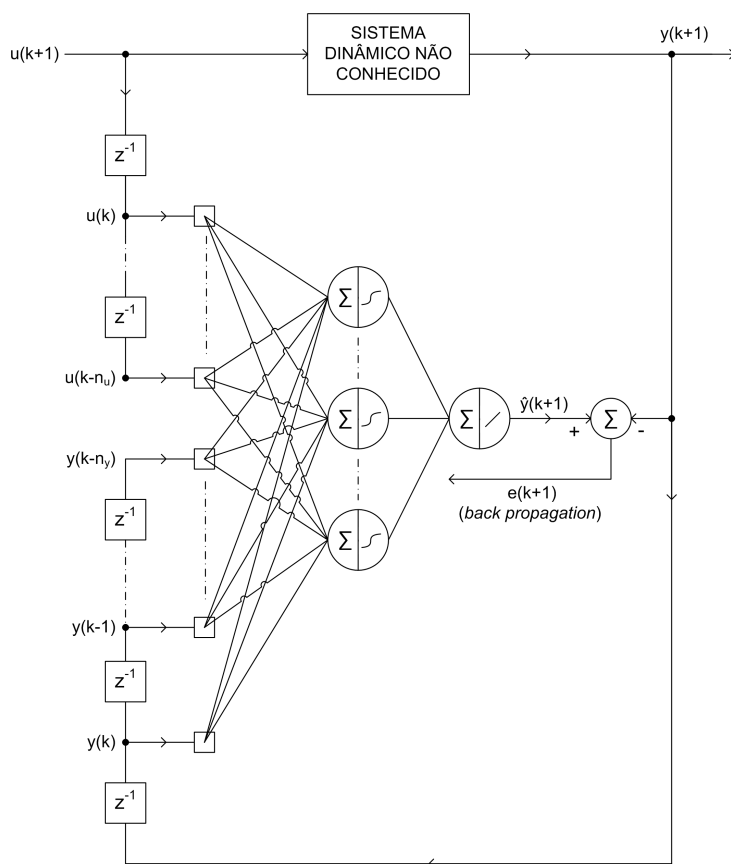


Figura 4.2: Rede neural utilizada no esquema de controle

da rede neural (Demuth et al., 2008). Já o modelo paralelo apresenta realimentação da saída estimada. A diferença entre os dois tipos é mostrada na figura 4.3.

O controlador utilizado neste trabalho, conforme definições da Seção 2.3, é denominado: *Controlador Neural Adaptativo Híbrido Indireto*. Neural porque utiliza redes neurais em sua estrutura. Adaptativo porque realiza treinamento *online* da rede. Híbrido porque não utiliza em sua estrutura apenas redes neurais, no bloco do controlador utiliza-se uma lei de controle. Indireto porque após a definição dos pesos sinápticos da rede, estes não podem ser utilizados diretamente no controlador, se faz necessário uma fase intermediária para determinação do Jacobiano  $\hat{J}$ .




Figura 4.3: Arquiteturas Paralelo (a) e Série-Paralelo (b).

### 4.2.1 A Lei de Controle

A lei de controle utilizada, ou seja, o cálculo da nova ação de controle, está baseada na avaliação da taxa de variação da saída  $y(k + d)$  com relação à entrada da planta  $u(k)$ , o *Jacobiano*, representado na equação (4.1), sendo  $d$  o atraso de transporte da planta.

$$J(k + d) = \frac{\partial y(k + d)}{\partial u(k)} \quad (4.1)$$

Analogamente, com base na saída do estimador, o *Jacobiano* é dado por:

$$\hat{J}(k + d) = \frac{\partial \hat{y}(k + d)}{\partial u(k)} \quad (4.2)$$

Tomando a aproximação da derivada, segue:

$$\hat{J}(k + d) = \frac{\partial \hat{y}(k + d)}{\partial u(k)} \cong \frac{\Delta \hat{y}(k + d)}{\Delta u(k)} \quad (4.3)$$

$$\frac{\Delta \hat{y}(k + d)}{\Delta u(k)} = \frac{\hat{y}(k + d) - \hat{y}(k + d - 1)}{u(k) - u(k - 1)} \quad (4.4)$$

Substituindo (4.4) em (4.3):

$$\hat{J}(k + d) = \frac{\hat{y}(k + d) - \hat{y}(k + d - 1)}{u(k) - u(k - 1)} \quad (4.5)$$

Utiliza-se então a expressão (4.5) para determinação do próximo sinal de controle. No momento do cálculo da nova ação de controle, são conhecidos o último sinal de controle  $u(k-1)$ , a última saída estimada  $\hat{y}(k+d-1)$ , o último Jacobiano estimado  $\hat{J}(k+d-1)$  e o valor de referência desejado  $y_{ref}(k+d)$ . Substituindo os valores em (4.5), segue:

$$\hat{J}(k+d-1) = \frac{y_{ref}(k+d) - \hat{y}(k+d-1)}{u(k) - u(k-1)} \quad (4.6)$$

Isolando  $u(k)$  na equação (4.6) chega-se na equação (4.7) que representa a lei de controle utilizada na estratégia implementada neste trabalho.

$$u(k) = u(k-1) + \frac{y_{ref}(k+d) - \hat{y}(k+d-1)}{\hat{J}(k+d-1)} \quad (4.7)$$

O objetivo do estimador neural é obter a saída estimada da planta,  $\hat{y}$ , e a estimativa para o *Jacobiano* utilizados na equação (4.7) para obtenção do novo sinal de controle.

#### 4.2.2 Cálculo do Jacobiano

Após o treinamento da rede neural, os seus pesos sinápticos são utilizados para a estimação do *Jacobiano*. O desenvolvimento para a obtenção da expressão utilizada para o cálculo do Jacobiano estimado, conforme apresentado por Schnitman e de Barros Fontes (1999), pode ser visto a seguir.

Considere a figura 4.4, que representa a estrutura geral da rede neural proposta, sendo,

- $\mathbf{W}_1$  → Matriz de pesos entre a entrada e a camada escondida
- $\mathbf{W}_2$  → Matriz de pesos entre a camada escondida e o neurônio de saída
- $S$  → Função de ativação da camada escondida
- $b_i$  → termos de polarização dos neurônios da camada escondida
- $b_s$  → termo de polarização do neurônio da saída
- $N$  → Número de neurônios da camada escondida
- $X_i$  → Resultado do campo local induzido para o *iésimo* neurônio
- $n_y$  → Número de atrasos da saída
- $n_u$  → Número de atrasos da entrada
- $d$  → Tempo morto

A expressão que representa a saída da rede é dada por:

$$\hat{y}(k+d) = b_s + \sum_{i=1}^N W_2(1,i)S(X_i) \quad (4.8)$$

sendo,

$$X_i = b(i,1) + \sum_{j=1}^{n_y} W_1(i,j)y(k-j+1) + \sum_{j=1}^{n_u} W_1(i,n_y+j)u(k-j+1) \quad (4.9)$$




Figura 4.4: Esquema de rede neural utilizado para o desenvolvimento do cálculo do Jacobiano

Baseado na equação (4.8), o *Jacobiano* pode ser expresso como:

$$\frac{\partial \hat{y}(k+d)}{\partial u(k)} = \frac{\partial}{\partial u(k)} \left[ b_s + \sum_{i=1}^N W_2(1,i)S(X_i) \right] \quad (4.10)$$

A equação pode ser reescrita como:

$$\frac{\partial \hat{y}(k+d)}{\partial u(k)} = \sum_{i=1}^N W_2(1,i) S'(X_i) \frac{\partial X_i}{\partial u(k)} \quad (4.11)$$

sendo,

$$S' = \frac{dS}{dX_i} = (1 - \tanh(X_i)^2) \quad (4.12)$$

e,

$$\begin{aligned} \frac{\partial X_i}{\partial u(k)} &= \frac{\partial}{\partial u(k)} \{b(i,1)\} + \\ &\frac{\partial}{\partial u(k)} \left\{ \sum_{j=1}^{n_y} W_1(i,j) y(k-j+1) \right\} + \\ &\frac{\partial}{\partial u(k)} \left\{ \sum_{j=1}^{n_u} W_1(i,n+j) u(k-j+1) \right\} \end{aligned} \quad (4.13)$$

Cancelando os termos que não dependem de  $u$ , segue:

$$\frac{\partial X_i}{\partial u(k)} = W_1(i,n+1) \quad (4.14)$$

Substituindo (4.14) em (4.11):

$$\frac{\partial \hat{y}(k+d)}{\partial u(k)} = \sum_{i=1}^N W_2(1,i) S'(X_i) W_1(i,n+1) \quad (4.15)$$

A equação (4.15) é a equação utilizada para o cálculo do *Jacobiano* utilizando-se os pesos sinápticos do identificador neural.

### 4.2.3 Taxa de Aprendizado Adaptativa

A taxa de aprendizado adaptativa ou simplesmente  $\eta$  – *Adaptativo* é uma proposta para aceleração da etapa de treinamento das redes neurais que utilizam treinamento *backpropagation*

baseado no *gradiente descendente*. Além de acelerar o treinamento, esta técnica também evita a instabilidade. Se  $\eta$  for muito grande o algoritmo pode oscilar e se tornar instável. Se  $\eta$  for muito pequeno o algoritmo leva muito tempo para convergir (Demuth et al., 2008).

A proposta sugere alterar o algoritmo padrão de treinamento incluindo uma função que varie o  $\eta$  de acordo com o desempenho global do treinamento, com o objetivo de manter o passo grande o suficiente para acelerar o treinamento e sem deixá-lo instável. O primeiro passo é calcular a saída da rede e seu índice de desempenho global. Após a retropropagação do erro, novos pesos e os termos de polarização são calculados, usando o  $\eta$  inicial, encerrando uma época do treinamento. Em seguida é calculada a nova saída e o erro da rede. Se o erro atual excede o anterior em 1,04, os novos pesos e termos de polarização são descartados e o  $\eta$  é ajustado com uma taxa de 0,7. Se o erro atual for menor que o erro anterior, o  $\eta$  é ajustado numa taxa de 1,05 (Demuth et al., 2008). As taxas de ajuste para o  $\eta$  utilizadas são as mesmas tipicamente sugeridas na utilização deste algoritmo (Demuth et al., 2008; Rezende e Maitelli, 1999; Maitelli e de Rezende, 2001).

```

Erro_Aux2 = Erro_Global;
Se (Erro_Aux2 ≤ 1,04 · Erro_Aux1)
    Se (Erro_Aux2 > Erro_Aux1)
        η = η;
    Senão
        η = 1,05 · η;
Senão
    η = 0,7 · η;
Fim
Erro_Aux1 = Erro_Aux2;

```

Existem outros métodos que também aceleram o treinamento, como por exemplo o *Super-SAB* e o *Delta-Bar-Delta* (Rezende e Maitelli, 1999). Estes últimos são métodos com estratégias locais, ou seja, definem uma taxa de aprendizado para cada neurônio ou camada. O  $\eta$  – *Adaptativo*, utilizado neste trabalho, define uma taxa global. A grande vantagem desta técnica é sua simplicidade. Segundo Maitelli e de Rezende (2001), apesar desta simplicidade o método apresenta bons resultados com relação à aceleração do treinamento.

#### 4.2.4 Teorema de Estabilidade e Análise de Robustez

Uma das vantagens da escolha da técnica de controle adaptativo neural híbrido indireto foi que ela já se apresentava com estudo de estabilidade e um teorema que permite avaliar sua robustez. Esta análise foi apresentada em Maitelli e Filho (2003b).

##### 4.2.4.1 Teorema de Estabilidade

O teorema da estabilidade e convergência do identificador neural, do tipo *MLP*, é baseado no seguinte *Lema*, que foi estabelecido com base no *método direto de Lyapunov* (Ng, 1997) *apud* (Maitelli e Filho, 2003b).

*Lema:*

"Sejam  $\eta^o$  e  $\eta^h$  as taxas de aprendizado da camada de saída e da camada escondida, respectivamente. Para garantir a convergência e estabilidade é suficiente encontrar as taxas de aprendizado conforme segue:

$$0 < \eta^o < \frac{1}{(D_{o,max})^2} \quad (4.16)$$

$$0 < \eta^h < \frac{1}{(D_{h,max})^2} \quad (4.17)$$

sendo,

$$D_{o,max} = \max_k \|D_o(k)\| \quad D_{h,max} = \max_k \|D_h(k)\|_F$$

$$D_o(k) = \frac{\partial \hat{y}(k)}{\partial W_o(k-1)} \quad D_h(k) = \frac{\partial \hat{y}(k)}{\partial W_h(k-1)}$$

Os símbolos  $\| \cdot \|$  e  $\| \cdot \|_F$  são, respectivamente, a norma *Euclidiana* e a norma *Frobenius*<sup>1</sup>.

---

<sup>1</sup>Norma Euclidiana:  $\|\mathbf{x}\| = \sqrt{\sum_{i=1}^n |x_i|^2}$   
 Norma Frobenius:  $\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^n \left( \sum_{j=1}^m |a_{ij}|^2 \right)}$



Para aplicação do *Lema* citado acima, na prática, utiliza-se o seguinte teorema:

*Teorema de Convergência e Estabilidade para o Identificador Neural:*

"Para garantir convergência e estabilidade, é suficiente escolher as constantes de aprendizagem da seguinte maneira:

$$0 < \eta^o < \frac{1}{p} \quad (4.18)$$

$$0 < \eta^h < \frac{1}{[(2n - d + 2)p] (w_{o,max} \cdot x_{max})^2} \quad (4.19)$$

sendo,

- $\eta^h$  → taxa de aprendizado da camada escondida
- $\eta^o$  → taxa de aprendizado do neurônio de saída
- $p$  → número de neurônios da camada escondida
- $n$  → ordem do modelo
- $d$  → atraso do modelo
- $(2n - d + 2)$  → número de entradas
- $x_{max}$  → valor da maior entrada da rede neural
- $w_{o,max}$  → valor do maior peso entre a camada escondida e a saída

Para este trabalho foi adotada uma única taxa de aprendizado para todos os neurônios do identificador neural. Neste caso, deve-se adotar o menor valor entre os calculados com as expressões (4.18) e (4.19).

$$\eta = \min(\eta^o, \eta^h) \quad (4.20)$$

Como exemplo será utilizada uma rede neural com três entradas, três neurônios na camada escondida, com função de ativação *tanh* e um neurônio de saída com função de ativação-linear para comprovação do *Teorema de Convergência e Estabilidade para o Identificador Neural*.

$$\hat{y} = o_{h1} \cdot w_{41} + o_{h2} \cdot w_{42} + o_{h3} \cdot w_{43} + b_4 \quad (4.21)$$

Para a camada de saída:

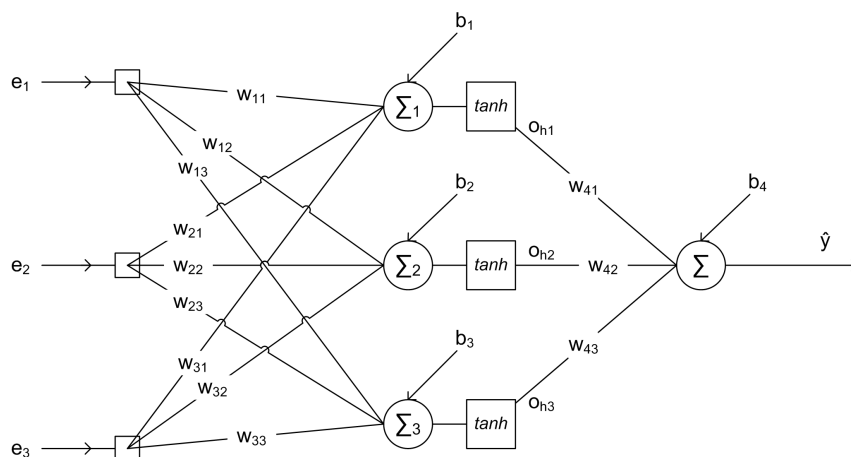


Figura 4.5: Rede neural para o exemplo de aplicação do Lema de Estabilidade

$$\frac{\partial \hat{y}}{\partial w_{41}} = o_{h1} \quad \frac{\partial \hat{y}}{\partial w_{42}} = o_{h2} \quad \frac{\partial \hat{y}}{\partial w_{43}} = o_{h3}$$

Então,

$$\frac{\partial \hat{y}}{\partial W_o} = [o_{h1}, o_{h2}, o_{h3}] \quad (4.22)$$

Como as funções de ativação da camada escondida são do tipo sigmóide, mais precisamente  $\tanh$ ,  $|o_{hj}| \leq 1$  para  $j = 1, 2, \dots, p$ , sendo  $p$  o número de neurônios da camada escondida, ou seja, para cada membro do vetor dado pela equação (4.22), o maior valor será no máximo 1.

Pela definição da *Norma Euclidiana*:

$$\|D_o\| \leq \sqrt{3} \quad (4.23)$$

Logo, substituindo (4.23) em (4.16):

$$0 < \eta^o < \frac{1}{3} \quad (4.24)$$

Para a camada escondida:

A saída da rede com relação aos seus pesos entre as entradas e a camada escondida pode ser escrita da seguinte forma:

$$\begin{aligned}\hat{y} &= f [e_1 \cdot w_{11} + e_2 \cdot w_{21} + e_3 \cdot w_{31} + b_1] \cdot w_{41} \\ &+ f [e_1 \cdot w_{12} + e_2 \cdot w_{22} + e_3 \cdot w_{32} + b_2] \cdot w_{42} \\ &+ f [e_1 \cdot w_{13} + e_2 \cdot w_{23} + e_3 \cdot w_{33} + b_3] \cdot w_{43}\end{aligned}\quad (4.25)$$

Sabendo que  $f'_{max} = 1$ :

$$\begin{aligned}\frac{\partial \hat{y}}{\partial w_{11}} &= e_1 \cdot w_{41} & \frac{\partial \hat{y}}{\partial w_{21}} &= e_2 \cdot w_{41} & \frac{\partial \hat{y}}{\partial w_{31}} &= e_3 \cdot w_{41} \\ \frac{\partial \hat{y}}{\partial w_{12}} &= e_1 \cdot w_{42} & \frac{\partial \hat{y}}{\partial w_{22}} &= e_2 \cdot w_{42} & \frac{\partial \hat{y}}{\partial w_{32}} &= e_3 \cdot w_{42} \\ \frac{\partial \hat{y}}{\partial w_{13}} &= e_1 \cdot w_{43} & \frac{\partial \hat{y}}{\partial w_{23}} &= e_2 \cdot w_{43} & \frac{\partial \hat{y}}{\partial w_{33}} &= e_3 \cdot w_{43}\end{aligned}\quad (4.26)$$

Pela definição da *Norma de Frobenius*:

$$\|D_h\| \leq \sqrt{3 \times 3} \cdot e_{max} \cdot w_{o,max} \quad (4.27)$$

Logo, substituindo (4.27) em (4.17):

$$0 < \eta^h < \frac{1}{3 \times 3 \cdot (e_{max} \cdot w_{o,max})^2} \quad (4.28)$$

#### 4.2.4.2 Análise de Robustez

Também como resultado do trabalho (Maitelli e Filho, 2003b), segue definição do *Teorema da Robustez do Erro de Controle* que permite calcular o limite máximo para o erro de controle. Este teorema define o limite em função do erro de treinamento  $\epsilon$  da rede neural.

Avaliando a equação (4.7) para o cálculo da nova ação de controle e considerando que  $\hat{y}(k + d - 1) = y(k + d - 1) - \hat{e}(k + d - 1)$ , sendo  $\hat{e}$  o erro de treinamento, segue:

$$y_{ref}(k+d) = [u(k) - u(k-1)] \cdot \hat{J}(k+d-1) + y(k+d-1) - \hat{e}(k+d-1) \quad (4.29)$$

Subtraindo  $y(k+d)$  dos dois lados da equação (4.29) para isolar o erro de controle  $w_c = y_{ref}(k+d) - y(k+d)$ , segue:

$$\begin{aligned} y_{ref}(k+d) - y(k+d) &= [u(k) - u(k-1)] \cdot \hat{J}(k+d-1) + \\ &\quad y(k+d-1) - y(k+d) - \hat{e}(k+d-1) \\ w_c(k+d) &= \Delta u(k) \cdot \hat{J}(k+d-1) - \Delta y(k+d) - \hat{e}(k+d-1) \end{aligned} \quad (4.30)$$

Supondo que a partir do instante  $k = k_c$  o sinal de controle estabilize, segue:

$$w_c(k+d) = -\Delta y(k+d) - \hat{e}(k+d-1) \quad (4.31)$$

Usando o conceito de desigualdade triangular<sup>2</sup>:

$$|w_c(k+d)| \leq |\Delta y(k+d)| + |\hat{e}(k+d-1)| \quad (4.32)$$

A primeira parcela de (4.32) tende a anular-se na medida que passa-se de  $k_c + d$ .

$$\lim_{\substack{M \rightarrow \infty \\ \Delta u(k)=0, \forall k > k_c}} |w_c(k+d+M)| \leq |\hat{e}(k+d+M-1)| \quad (4.33)$$

Aplicando-se a definição do erro global de treinamento:

$$\begin{aligned} \epsilon &= \frac{1}{2}(y - \hat{y})^2 \\ 2 \cdot \epsilon &= \hat{e}^2 \\ |\hat{e}| &= \left| \sqrt{2\epsilon} \right| \end{aligned} \quad (4.34)$$

---

<sup>2</sup> $|u+v| \leq |u| + |v|$

Logo,

$$\lim_{\substack{M \rightarrow \infty \\ \Delta u(k)=0, \forall k > k_c}} |w_c(k+d+M)| \leq \left| \sqrt{2\epsilon} \right| \quad (4.35)$$

*Teorema:*

"Seja um sistema de Controle Híbrido Indireto de uma planta *BIBO* estável, dada pelos seus pares de entrada-saída  $[u(k), y(k+d)]$ . Sendo  $\Omega_c$  o conjunto dos erros de controle,  $\Omega_c(k+d) = [y_{ref}(k+d) - y(k+d)]$ , pode-se afirmar que:

$$\sup_{\substack{M \rightarrow \infty \\ \Delta u(k)=0, \forall k > k_c}} \Omega_c(k+d+M) = \left| \sqrt{2\epsilon} \right| \quad (4.36)$$

em que  $k_c$  é tal que  $\Delta u(k) = 0, \forall k > k_c$ ,  $M$  é o intervalo de estabilização da planta contado a partir de  $k_c + d$  e  $\epsilon$  é a tolerância especificada para a convergência do treinamento da rede neural do identificador".

Verifica-se que o maior erro de controle possível, após a estabilização da planta, depende da tolerância  $\epsilon$  escolhida para o treinamento da rede neural do estimador.

#### 4.2.5 O Algoritmo para Implementação do Esquema de Controle

Definidas a arquitetura da rede neural, a estratégia para o cálculo do *Jacobiano*, a estratégia para aceleração do treinamento, a lei de controle e as expressões que serão implementadas para a garantia de estabilidade, o esquema de controle está projetado e pronto para ser implementado. Sua implementação foi desenvolvida em Matlab com a utilização das rotinas disponibilizadas por Norgaard em <http://www.iau.dtu.dk/research/control/nnsysid.html>. Suas rotinas originais tiveram algumas modificações para implementação do  $\eta$ -*Adaptativo* e da normalização dos dados de treinamento. Essas funções foram preferidas em relação às funções originais do Matlab devido a já estarem prontas com rotinas de preparação da matriz de dados utilizados na entrada da rede neural e por também já possuírem rotinas para o cálculo do *Jacobiano*.

Outro ponto que foi avaliado antes da implementação do esquema de controle foi a forma de treinamento. Sequencial ou por lote? Segundo Demuth et al. (2008), para redes neurais dinâmicas e com treinamento *online* o mais usado é o treinamento sequencial, que foi utilizado nas

implementações deste trabalho.

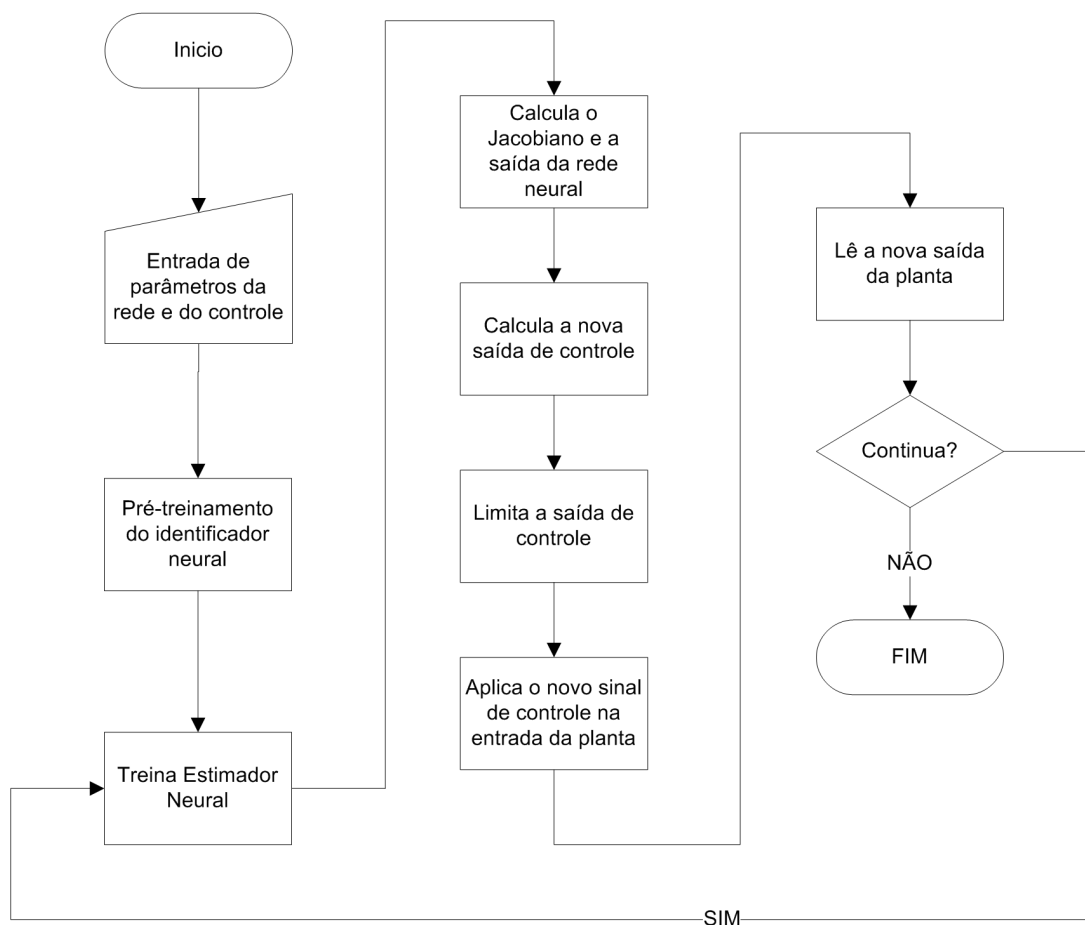


Figura 4.6: Algoritmo para implementação da estratégia de controle

As etapas do algoritmo apresentado na figura 4.6 são descritas a seguir:

**Entrada de parâmetros da rede neural e do controle** - Supondo já definidos o tamanho da janela de treinamento, a ordem do identificador, o tempo de amostragem, o número de neurônios na camada escondida, o erro meta, o número máximo de iterações para o treinamento da rede neural, os limites para o sinal de controle, a primeira etapa do algoritmo é informar estes parâmetros ao esquema de controle.

**Pré-treinamento do identificador neural** - Como forma de evitar que, ao fechar a malha de controle com o esquema proposto, o identificador neural apresente uma resposta muito longe da desejada e, conseqüentemente, gere também respostas indesejadas na saída da planta, foi proposta uma fase de pré-treinamento do identificador neural, uma forma de deixar que a rede

neural, antes de atuar no esquema de controle, se aproxime da condição de aprendizado ideal. Nesta etapa é realizada a coleta de dados de entrada e saída da planta, porém sem atuação do esquema proposto, ou seja, o sinal de controle não é calculado. O identificador neural é treinado com estes dados e, a cada nova etapa de amostragem, esta é retreinada e sua saída pode ser acompanhada com auxílio de gráficos e *displays*. A ideia é que a saída do identificador se aproxime da saída real da planta. Neste ponto, quando o identificador neural apresenta respostas próximas as da planta, acredita-se que o cálculo do Jacobiano com seus pesos sinápticos dê respostas condizentes e a malha de controle com o esquema proposto pode ser fechada. Os testes realizados neste trabalho mostram que este procedimento é válido. O tempo mínimo de pré-treinamento para esta fase é igual ao tempo determinado para a janela de treinamento.

**Treina Estimador Neural** - Entre o fim da etapa anterior e o início desta existe um período de tempo equivalente ao tempo de amostragem definido inicialmente. A janela de treinamento foi completada na etapa anterior e como já se passou o tempo para mais uma amostra, novos dados de entrada e saída são coletados e os mais antigos são excluídos da janela, fornecendo assim uma nova janela de treinamento para o identificador neural. Este então é treinado nesta etapa. Aqui inicia-se o *loop* de controle proposto.

**Calcula o Jacobiano e a saída da rede neural** - Com o identificador neural treinado na etapa anterior, esta etapa realiza a simulação da saída da rede e extrai seus pesos para o cálculo do Jacobiano.

**Calcula a nova saída de controle** - Com a saída e o Jacobiano estimados na etapa anterior, estes são utilizados na lei de controle para o cálculo na nova ação de controle.

**Limita a saída de controle** - Nesta etapa é avaliado se a saída de controle está dentro dos limites definidos inicialmente de acordo com as possibilidades do atuador e do processo.

**Aplica o novo sinal de controle na entrada da planta** - Nesta etapa o novo sinal de controle, calculado na etapa anterior, é aplicado na entrada da planta.

**Lê a nova saída da planta** - Após aplicado o sinal de controle, esta etapa realiza a coleta da nova saída da planta. Em seguida o ciclo é reiniciado, voltando à etapa de Treinamento do estimador neural.

# Capítulo 5

## Aplicações da Estratégia de Controle em Plantas Simuladas e Piloto

### 5.1 Introdução

Como forma de conhecer o funcionamento da técnica proposta por Maitelli e Filho (2003a), avaliar a variação de parâmetros e evitar problemas durante a aplicação no sistema industrial, foram realizados vários experimentos com uma planta piloto de neutralização de  $pH$ . Este tipo de sistema é muito utilizado para testes de controladores visto seu alto grau de não-linearidade e sua característica de grandes alterações na saída com uma pequena variação da entrada para certas regiões de operação (Paganoto, 2008). O primeiro passo foi reproduzir o resultado obtido por Maitelli e Filho (2003a). Em seguida, com o pleno conhecimento do algoritmo, partiu-se para os testes na planta piloto.

Foi realizada uma série de experimentos com o modelo fenomenológico da planta piloto de  $pH$ , desenvolvido por Campos (2007), simulados no Matlab. Foram realizados vários testes variando-se o número de neurônios, a taxa de amostragem, o tamanho da janela de treinamento e o número de atrasos de entrada e saída utilizados na entrada do identificador. Com os resultados obtidos na simulação da planta de neutralização de  $pH$ , partiu-se para os testes na planta piloto real.

A planta piloto de neutralização de  $pH$  utilizada está instalada no laboratório de Modelagem, Otimização e Controle de Processos (MOCP) do Centro Universitário do Leste de Minas Gerais (UnilesteMG), situado em Coronel Fabriciano.



O desenvolvimento destes experimentos e os resultados são vistos nas seções que seguem.

## 5.2 Aplicação em Um Sistema Não-linear Real

Tendo verificado o funcionamento da técnica proposta em um sistema teórico, partiu-se para os testes em um sistema real. O sistema escolhido foi a planta de neutralização de  $pH$  do Centro Universitário do Leste de Minas Gerais, em escala piloto (ver figura 5.1), construída com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Campos, 2007).




Figura 5.1: Foto frontal da planta piloto de neutralização de pH

### 5.2.1 Conceitos Básicos sobre o Processo de Neutralização de pH

A neutralização de pH consiste na interação entre os íons *oxonium*  $H_3O^+$  (íon de hidrogênio  $H^+$ ), provenientes da solução ácida, e os íons de  $OH^-$ , provenientes da solução alcalina, produzindo água ( $H_2O$ ) (Ylén, 2001).

Considerando o exemplo da mistura de ácido clorídrico e soda cáustica:



Uma solução ou mistura é ácida ( $pH < 7$ ) quando a concentração de íons  $H^+$  é maior que a concentração de íons  $OH^-$ . Uma solução ou mistura é dita alcalina ( $pH > 7$ ) quando a concentração de íons  $H^+$  é menor que a concentração de íons  $OH^-$ . Uma solução ou mistura é dita neutra quando as concentrações de íons  $H^+$  e  $OH^-$  são iguais.

A medição do  $pH$  (potencial hidrogeniônico), que indica o nível de acidez de uma solução, é obtido da seguinte forma:

$$pH = -\log_{10}[H^+] \quad (5.1)$$

Um sistema com o objetivo de realizar a neutralização do  $pH$  de uma mistura é constituído basicamente de um reator contínuo com três fluxos controlados na entrada: o fluxo de solução ácida, o de solução alcalina e o de solução tampão. A variação na vazão de cada fluxo determina um acréscimo ou um decréscimo no valor do  $pH$  da mistura.

Mantendo as vazões de ácido e tampão constantes e atuando na vazão de base em um sistema de neutralização de  $pH$ , pode-se tirar a curva estática que indica os valores de  $pH$  para cada valor de vazão da base. Uma curva típica é mostrada na figura 5.2. Nesta figura percebe-se o comportamento característico deste sistema, conforme comentado por (Paganoto, 2008) no primeiro parágrafo deste capítulo. Para o caso desta figura não foi adicionada a solução tampão.

A solução tampão, conjugada de ácido e base, tem o objetivo de proporcionar à mistura a capacidade de resistir às mudanças no valor do  $pH$ , na região de neutralização, na ocorrência da adição de pequenas quantidades de ácido ou base (Ylén, 2001). Na figura 5.3 é possível verificar o efeito da adição de solução tampão durante o teste de obtenção da curva estática. Percebe-se que na região de neutralização, próximo ao  $pH$  7, a curva estática é suavizada.

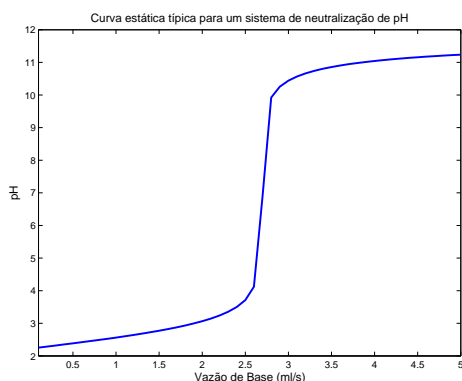


Figura 5.2: Curva estática típica de um sistema de neutralização de pH sem adição de tampão

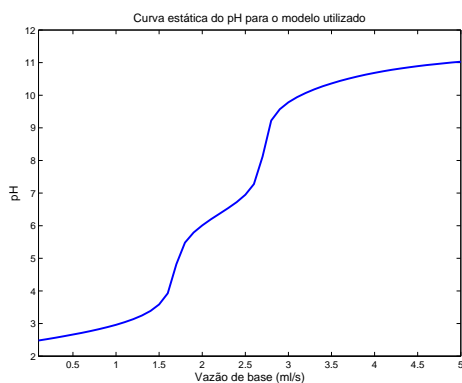


Figura 5.3: Curva estática típica de um sistema de neutralização de pH com adição de tampão

## 5.2.2 A Planta Piloto

A planta utilizada é constituída de um reator contínuo, perfeitamente agitado, com três fluxos de entrada: um de ácido ( $HCl$ ), um de base ( $NaOH$ ) e outro de solução tampão ( $NaHCO_3$ ). As concentrações utilizadas e o modo de preparo das soluções pode ser visto em Campos (2007). Existe ainda um fluxo de saída da mistura, o orifício de saída é disposto em uma certa altura do reator, com o objetivo de renovar a mistura e manter o processo contínuo e volume constante. Imerso no reator está o sensor de  $pH$ . Para alimentar o reator existem três tanques, cada um deles com uma das soluções citadas acima, equipados com bombas de dosagem. Estas bombas são de velocidade variável, dependendo do ajuste no sinal de voltagem na entrada, sua velocidade é alterada e, conseqüentemente, sua vazão de saída também é alterada. Na figura 5.4 é apresentado o diagrama esquemático da planta e nas figuras 5.5, 5.6 e 5.7 são apresentados os gráficos com a relação de voltagem x vazão das bombas. Estes dados são os mesmos obtidos em

Campos (2007). Para este trabalho a etapa de obtenção da relação vazão x tensão não foi refeita. A ideia é que mesmo com alterações no funcionamento das bombas, o esquema de controle se adapte e consiga realizar a controle do pH.




Figura 5.4: Esquema da planta piloto de neutralização de pH

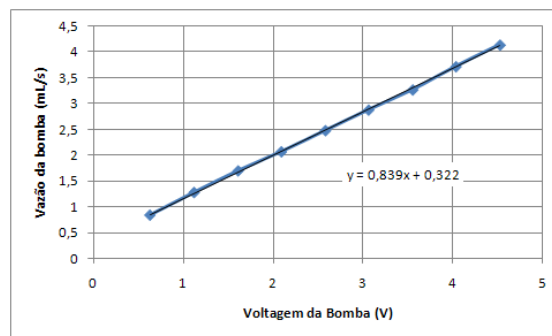


Figura 5.5: Relação Volts x Vazão para a bomba Q1 (ácido)

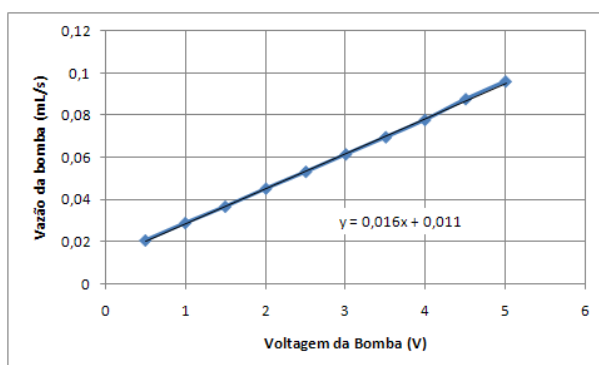


Figura 5.6: Relação Volts x Vazão para a bomba Q2 (tampão)




Figura 5.7: Relação Volts x Vazão para a bomba Q3 (base)

### 5.2.3 Aplicação no Modelo da Planta Piloto

Em Campos (2007) foi feito o desenvolvimento de um modelo fenomenológico de uma planta de neutralização de  $pH$ . Este modelo foi utilizado para simulações da técnica de controle neural adaptativa testada neste trabalho. Para se obter a saída da planta de  $pH$  simulada, calcula-se a nova saída do controlador e integra-se o modelo proposto, utilizando-se das funções de integração do Matlab (ode45 ou ode23). Os testes foram realizados com atuação na bomba Q3, de solução alcalina, mantendo as vazões de ácido e solução tampão constantes.

Para as simulações com o modelo da planta piloto foi considerada a planta com a curva estática apresentada na figura 5.3. Com base na curva estática e em simulações isoladas da planta foram escolhidos os valores de referência e seus respectivos tempos de permanência. Os patamares escolhidos para o  $pH$  foram 7, 10,5 e 3,5, dispostos de forma que se tenha uma variação grande da referência e outra intermediária. Definiu-se também que o tempo de permanência em cada patamar deveria ser de trinta minutos, suficiente para o acompanhamento da transição e da

estabilização dos sinais de controle e saída da planta, na passagem de um patamar para outro. O sinal de referência utilizado para todos os testes com o modelo da planta piloto pode ser visto na figura 5.8.

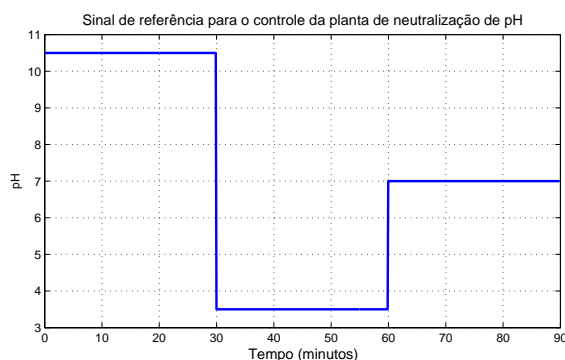


Figura 5.8: Sinal de referência utilizado nas simulações com a planta de neutralização de pH

### 5.2.3.1 Escolha do tempo de amostragem

Para a determinação do tempo de amostragem a ser utilizado no algoritmo de controle foi seguido o procedimento apresentado na Seção 3.2.2.

Segundo Aguirre (2004), quando o sistema a ser modelado apresenta características não-lineares, o sinal de entrada para excitação do sistema deve variar, na amplitude e na frequência, de forma aleatória, de modo a excitar todas as suas dinâmicas. Para o presente trabalho foi gerado o sinal de entrada conforme mostrado na figura 5.9(a). O tempo de amostragem utilizado foi de 1 segundo. Os tempos mínimo e máximo de permanência em cada patamar foram definidos como 30 segundos e 60 segundos, respectivamente. Na figura 5.9(b) é apresentado o sinal de saída.




Figura 5.9: Dados de entrada (a) e saída (b) simulados para o procedimento de determinação do tempo de amostragem

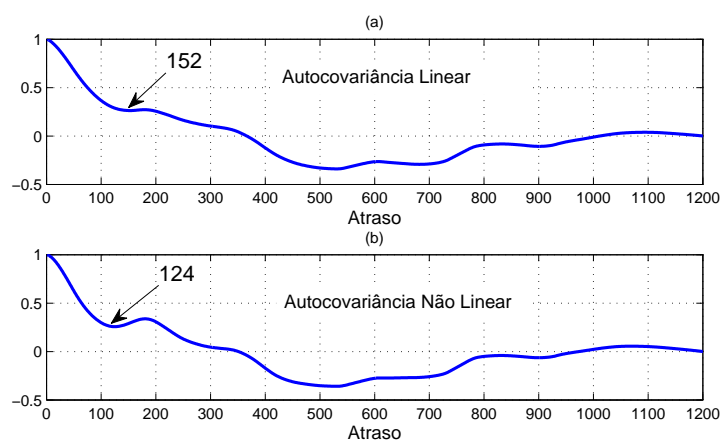


Figura 5.10: Autocovariâncias obtidas no procedimento de determinação do tempo de amostragem. (a) Autocovariância linear. (b) Autocovariância não-linear.

Verifica-se nos gráficos da figura 5.10 que o primeiro mínimo entre as duas autocovariâncias indica um  $\tau_m = 124$ . Utilizando a expressão (3.10), verifica-se que a faixa viável para o período de amostragem está entre 6.2 e 12.4. Para o presente trabalho foi adotado tempo de amostragem igual a 7 segundos.

### 5.2.3.2 Escolha da ordem do modelo

Conforme apresentado na seção 3.2.1, o resultado do algoritmo FNN parece ter uma forte dependência da escolha de  $R$ . Segundo Rhodes e Morari (1998), a partir de um determinado ponto para variação do  $R$ , a porcentagem de falsos vizinhos permanece aproximadamente constante. Esta afirmação foi confirmada nos resultados obtidos para este trabalho.

Foi verificado o resultado do algoritmo para  $R$  variando de 1 a 10 e para  $l = m$ , ou seja, foi avaliada a ordem global (ver figura 5.11).

Analisando-se os gráficos da figura 5.11 percebe-se que para o acréscimo no valor de  $R$ , a partir de 3, não se vê grandes diferenças na porcentagem de falsos vizinhos, conforme esperado. Os gráficos indicam uma ordem global igual a 2 para a planta de neutralização de  $pH$ , ou seja, a dinâmica do sistema pode ser modelada utilizando-se os regressores  $y(k-1)$ ,  $y(k-2)$ ,  $u(k-1)$  e  $u(k-2)$ .

O mesmo resultado de seleção de ordem para um sistema de neutralização de  $pH$  foi encontrado em Doherty (1999).

Para o tempo morto  $d$  foi adotado o valor 1, admitindo que o reator proporciona uma mistura




Figura 5.11: Resultado do algoritmo FNN (percentual de falsos vizinhos x ordem)

perfeita, sem atraso de transporte.

### 5.2.3.3 Resultados Obtidos

Após selecionados o tempo de amostragem ( $T_s = 7\text{seg.}$ ), a ordem do modelo ( $n_y = n_u = 2$ ) e seu tempo morto ( $d = 1$ ), partiu-se para as simulações do modelo da planta de neutralização de  $pH$ . Basicamente, estes são os pontos que podem ser avaliados com a coleta de dados da planta. Outros parâmetros como o número de neurônios da camada escondida, o erro meta, o número máximo de iterações e o tamanho da janela de treinamento foram avaliados durante os testes.

A padronização do sinal de referência, além de facilitar a avaliação visual, possibilitou a utilização de um índice de avaliação de desempenho. Para o caso deste trabalho foi utilizado o  $IAE^1$ . Existem outros índices de avaliação de desempenho que ponderam o tempo e maximizam ponderações para erros grandes e minimizam ponderações para erros pequenos. Como durante os testes ocorrem variações do patamar do sinal de referência e com a idéia de se avaliar também o resultado para erros pequenos, o  $IAE$  foi escolhido e sua formulação pode ser vista na equação

<sup>1</sup>Integral do Erro Absoluto, traduzido do Inglês *Integral Absolute Error*



(5.2).

$$IAE = \int_0^t |e(t)| dt \quad (5.2)$$

*Variando o número de neurônios e o tamanho da janela de treinamento*

A primeira série de experimentos realizada foi com a variação do número de neurônios da camada escondida e do tamanho da janela de treinamento. O número de neurônios foi avaliado entre os valores de 1 a 20 para os seguintes pontos: 1, 2, 3, 5, 7, 10, 15 e 20. O tamanho da janela de treinamento foi variado entre 5 e 150 amostras para os seguintes pontos: 5, 10, 20, 30, 50, 70, 90, 110, 130 e 150.

Foram realizadas nesta etapa um total de 800 simulações, resultado de 10 simulações para cada combinação de número de neurônios e janela de treinamento (10 x 8 x 10). Para cada combinação de número de neurônios e tamanho da janela, tirou-se a média do IAE para as 10 simulações, gerando o índice médio para cada combinação.

De acordo com o IAE, o melhor resultado foi encontrado para 90 amostras na janela de treinamento. Com relação ao número de neurônios percebe-se que quanto mais neurônios melhor é o resultado. Os resultados para cada variável pode ser visto nas figuras 5.12 e 5.13.




Figura 5.12: Índice de desempenho médio com relação à variação do número de neurônios da camada escondida (90 amostras para a janela de treinamento)

Como o resultado para 20 neurônios já se mostrou satisfatório, não foram realizados experimentos com um número maior de neurônios. Acredita-se que um número elevado de neurônios

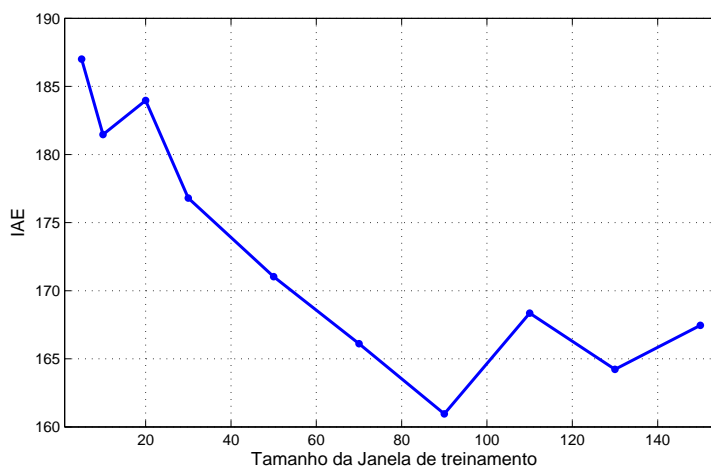


Figura 5.13: Índice de desempenho médio com relação à variação do tamanho da janela de treinamento (20 neurônios na camada escondida)

na camada escondida foi devido ao alto grau de não-linearidade da planta.

Avaliando o resultado da variação do tamanho da janela de treinamento, fica claro no gráfico da figura 5.13 que a partir de 90 amostras não houve melhora do desempenho do sistema de controle. Também não houve piora significativa. Para a janela de treinamento configurada de 90 a 150 amostras, o IAE ficou entre 161 e 168. Foi verificado visualmente nos gráficos obtidos que, para estes valores de tamanho da janela e para o IAE, a resposta é próxima da apresentada na figura 5.14. Esta análise indica que o número de 90 amostras foi suficiente para reproduzir a dinâmica do sistema.

A figura 5.14 mostra o resultado médio obtido com a configuração da rede neural para 20 neurônios na camada escondida e 90 amostras na janela de treinamento. Os 10 minutos iniciais foram utilizados para o pré-treinamento. Somente após o período de pré-treinamento o esquema de controle iniciou sua atuação na planta.

Outro resultado interessante, que já era previsto, é que aumentando-se o tamanho da janela de treinamento, a rede aprende mais e como consequência o controlador consegue antecipar ações e diminuir o sobressinal do sistema. As figuras 5.15 e 5.16 demonstram este efeito. A figura 5.15 apresenta o resultado para uma janela de 20 amostras enquanto a figura 5.16 apresenta o resultado para uma janela de 90 amostras. Percebe-se que o sistema, após os 60 minutos de teste, quando foi ajustada a referência de  $pH$  igual a 7, responde de forma diferente nas duas situações. Para o teste com 20 amostras a ação de controle só começa a diminuir quando o valor da saída da planta passa pela referência. Para o teste com 90 amostras a ação de controle começa




Figura 5.14: Resultado para 20 neurônios e 90 amostras de treinamento

a diminuir antes, exatamente dois minutos antes, ou seja, o esquema de controle com mais amostras de treinamento aprendeu melhor e reduziu o sobressinal. Porém, apesar de diminuir o sobressinal, o tempo de subida aumentou. Dependendo da necessidade de um projeto, essas variáveis devem ser avaliadas para ajuste do tamanho da janela de treinamento.

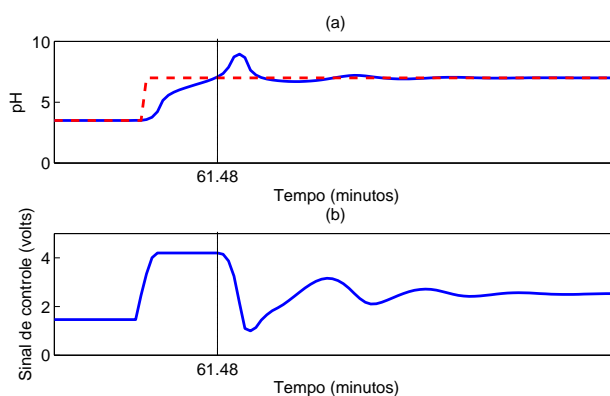


Figura 5.15: Resultado para a janela de treinamento com 20 amostras. (a) Linha contínua: valor de pH. Linha tracejada: sinal de referência. (b) Sinal de controle.




Figura 5.16: Resultado para a janela de treinamento com 90 amostras. (a) Linha contínua: valor de pH. Linha tracejada: sinal de referência. (b) Sinal de controle.

#### *Variando o tempo de amostragem*

Apesar de se ter realizado um estudo prévio do tempo de amostragem para o esquema de controle, foram realizados experimentos variando-o, como forma de comprovar o procedimento adotado. A figura 5.17 apresenta a variação do índice de desempenho com relação à variação do tempo de amostragem.

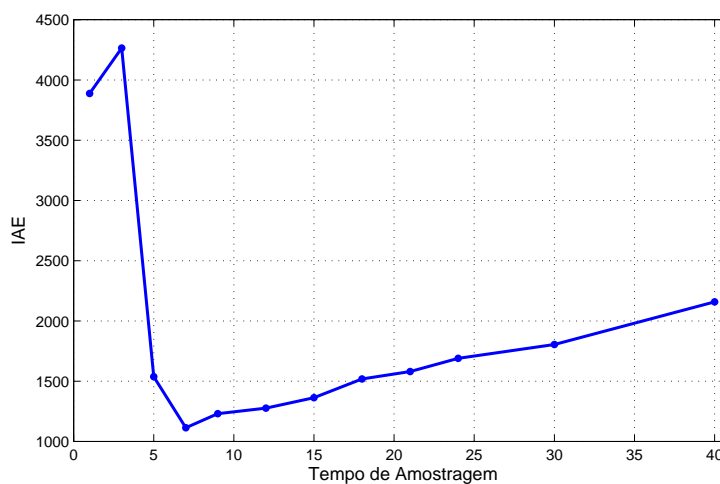


Figura 5.17: Variação do índice de desempenho com relação ao tempo de amostragem

Na figura 5.17 é possível observar que a escolha do tempo de amostragem igual a 7 segundos foi acertada. No estudo prévio foi observado que a taxa de amostragem ideal estaria entre 6.2 e 12.4 segundos. Na verdade, se ao invés de escolher o valor de 7 segundos, fosse escolhido qualquer outro valor dentro da faixa pré-determinada, o desempenho do controlador ainda estaria bem

próximo do encontrado para o valor de 7 segundos, conforme pode ser visto no gráfico da figura 5.17. A faixa pré-determinada coincide com a região onde o índice de desempenho é minimizado.

#### *Variando a ordem do modelo*

Da mesma forma que foi feito para o tempo de amostragem, testes com a variação da ordem do identificador neural foram realizados como forma de comprovar a análise prévia. A figura 5.18 apresenta a variação do índice de desempenho do esquema de controle com relação à variação da ordem, ou seja, variando o número de regressores utilizados na entrada da rede neural.




Figura 5.18: Variação do índice de desempenho com relação ao número de regressores da entrada e da saída

Percebe-se que, usando o índice de desempenho, a escolha da ordem seria 4. De acordo com a análise realizada com o algoritmo FNN, a escolha da ordem seria 2.

Realizando a análise visual das respostas dos testes nota-se que, apesar do menor *IAE* para quatro regressores de entrada e saída, a resposta apresenta um grande sobressinal para a referência de *pH* 7 (ver figura ??). O que explica o menor *IAE* para 4 regressores é que para os dois primeiros patamares (10.5 e 3.5), a resposta para 4 regressores diminuiu o sobressinal e a área sob o sobre-sinal do patamar de *pH* 7 é pequena, por ser um "pico", resultando em um menor *IAE*.

Analisando-se visualmente é perceptível que a melhor resposta está para a ordem 2 e que aumentando a ordem o sistema tende a oscilar. Os gráficos com as respostas para as ordens 1, 2,

3, 4, 6 e 9 podem ser visualizados nas figuras 5.19, 5.20, 5.21, 5.22, 5.23 e 5.24. Desta forma ficou comprovado o resultado encontrado com o algoritmo FNN.




Figura 5.19: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 1. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.




Figura 5.20: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 2. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.




Figura 5.21: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 3. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.




Figura 5.22: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 4. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.




Figura 5.23: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 6. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.




Figura 5.24: Resposta do modelo da planta de neutralização de pH utilizando a rede neural configurada com ordem 9. (a) Linha contínua: Sinal de saída do pH. Linha tracejada: Sinal de referência. (b) Sinal de controle.



### 5.2.4 Aplicação na Planta Piloto Real

Com os resultados obtidos no modelo da planta foi iniciado o teste na planta real trazendo as conclusões obtidas nos testes simulados. O algoritmo foi implementado em código Matlab e a conexão com a placa de aquisição da *National Instruments* foi feita através da instalação dos *drivers* desta no microcomputador utilizado para os testes.

Percebe-se na figura 5.1, na foto da planta piloto, o rótulo do tanque 1, de ácido, está indicando ácido nítrico ( $HNO_3$ ). O modelo da planta de neutralização de pH simulado neste trabalho considera a utilização deste mesmo ácido, porém, para os testes com a planta piloto foi utilizado o ácido clorídrico ( $HCl$ ). A substituição não teve nenhum motivo especial, simplesmente foi o ácido disponibilizado pelo laboratório de química.

#### 5.2.4.1 Resultados Obtidos

Após a implementação da técnica de controle neural adaptativa proposta, utilizando os melhores parâmetros encontrados nas simulações do modelo, foi observada a seguinte resposta (ver figura 5.25). Para as simulações com a planta piloto, os dois primeiros patamares do sinal de referência foram alterados de 10,5 para 10 e de 3,5 para 4. O motivo para a alteração foi a condição real da planta piloto, diferente da condição do modelo. Antes das simulações com o sinal de referência proposto foram realizados testes colocando-se a bomba de ácido no meio da faixa e variando-se a bomba de base. Foi verificado que os valores mínimo e máximo alcançados com os testes iam pouco além dos patamares definidos para os testes com o modelo, então, por este motivo, os patamares para os testes com a planta piloto foram alterados.




Figura 5.25: Resultado para aplicação do controle neural adaptativo na planta piloto de neutralização de pH

Percebe-se na figura 5.25 que para a referência de pH 7 o controlador apresentou oscilação, enquanto que nas outras faixas de operação o resultado mostra um rápido tempo de subida e quase nenhum sobressinal. Na passagem da referência 10 para 4, percebe-se que o valor de  $pH$ , na região de neutralização, não sofre nenhuma atenuação no ganho. Nos resultados da simulação do modelo (ver figura 5.14) é verificada uma atenuação do ganho na região de neutralização na passagem da referência de 10,5 para 3,5, efeito proporcionado pela solução tampão. Esta comparação é apresentada na figura 5.26.




Figura 5.26: Comparação do efeito do tampão na planta de neutralização de pH para o caso real (a) e para o modelo (b)

O resultado apresentado na figura 5.26 sugeriu verificar o resultado da simulação do controlador no modelo, sem a adição de solução tampão. Percebe-se no resultado para a simulação do modelo da planta (figura 5.27), sem a adição de tampão, que este também apresenta oscilação para a referência de pH 7. De acordo com o resultado apresentado é possível concluir que a curva estática para a planta piloto real aproxima-se mais da curva sem tampão (figura 5.2) do que para a curva com tampão (figura 5.3). Por este motivo o resultado do teste com a planta piloto real apresentou oscilação na faixa de operação para o pH 7.

Na tentativa de melhorar o resultado, outros experimentos com variações nos parâmetros (tamanho da janela de treinamento, número de regressores na entrada da rede neural, tempo de amostragem) foram realizados, porém não houve melhora da resposta.

Acredita-se que para sistemas que apresentem condições severas de controle, com regiões de ganho muito alto, como para o caso da planta piloto de neutralização de  $pH$ , o controlador implementado neste trabalho não apresentará resultados satisfatórios.

O processo de neutralização de pH apresenta variações muito grandes de uma faixa de operação para outra e o identificador neural, saindo da faixa de pH 4 para 7 não foi capaz de aprender e responder em tempo para convergir o sinal de saída, para o caso da planta piloto. Percebe-se que para o experimento com o modelo da planta, sem a adição de solução tampão, apresentado




Figura 5.27: Resultado da simulação do modelo da planta de neutralização de pH sem a adição de solução tampão. (a) Linha contínua: Valor do pH. Linha tracejada: sinal de referência. (b) Sinal de controle.

na figura 5.27, a saída tende a convergir para a referência, porém lentamente.

O que ainda poderia ser investigado para este caso e, possivelmente, melhorar o resultado, seria inicializar o identificador neural com pesos e termos de polarização avaliados em um treinamento *offline*, em todas as faixas de operação, inclusive para a faixa do pH 7, da mesma forma que em um procedimento para implementação de um algoritmo NPC (*Neural Predictive Control*). O esquema teria desta forma um conhecimento global, ou seja, de todas as regiões e, supostamente, poderia indicar um melhor ajuste para o controlador. Apesar de ser uma possível solução para este caso, este procedimento elimina uma das vantagens desta proposta, que é treinar *online*, apenas durante uma janela de tempo, sem a necessidade de um procedimento de coleta de dados e treinamento prévios.

# Capítulo 6

## Aplicação da Técnica de Controle Proposta em uma Planta Industrial

### 6.1 Introdução

Conforme proposto como um dos objetivos deste trabalho, a estratégia foi implementada e testada numa malha de controle de vazão em uma das plantas de regeneração de ácido clorídrico da Usiminas, em Ipatinga. Esta malha foi escolhida devido a sua baixa criticidade para o processo e por possuir um sistema de automação e controle moderno, com rede de comunicação padrão OPC<sup>1</sup>, possibilitando assim o fácil acesso à leitura e escrita nas variáveis do processo através de um computador portátil rodando o Matlab. Os testes foram realizados apenas com o objetivo de avaliação da estratégia de controle, após a realização dos testes o controlador neural foi retirado e foi mantido em operação o controlador original.

Apesar do resultado oscilatório para uma das faixas de operação na implementação para a planta piloto de neutralização de  $pH$ , a implementação da estratégia numa planta industrial não foi desencorajada, pois o processo alvo não apresenta condições severas como para o caso da planta piloto.

O processo, os passos para a implementação e os resultados obtidos são apresentados nas seções que se seguem.

---

<sup>1</sup>*Ole for Proccess Control*

## 6.2 O Processo de Regeneração de Ácido Clorídrico

O ácido clorídrico (HCl) é utilizado nas indústrias siderúrgicas nas linhas de decapagem. A decapagem é um processo de fundamental importância para a remoção da camada de óxidos superficial (carepa) das bobinas e adequação da sua superfície para processos posteriores.

Durante o processo de laminação a quente, em função da elevada temperatura, ocorre o favorecimento da reação do oxigênio contido na atmosfera com o metal base da placa, recobrindo a superfície do material com uma camada formada de óxidos de diferentes composições e espessuras em função da temperatura, do tempo de processo, das condições de resfriamento, do meio ambiente e do tipo de aço.




Para a remoção de óxidos metálicos existem quatro processos distintos:

- Decapagem Mecânica: é o processo de remoção da carepa por escovação, tamboreamento, jato abrasivo, areia quartzídica, esferas de aço ou flexionamento;
- Decapagem Térmica: é o processo de limpeza de graxa por recozimento, por chama e com pó de ferro;
- Decapagem Química: consiste no processo de remoção da carepa pelo processo de ataque químico, sendo que o tipo de ácido utilizado e temperatura de processo podem mudar conforme o metal base. Na Usiminas, em Ipatinga, as decapagens trabalham com ácido clorídrico;
- Decapagem Eletrolítica: é composta dos processos de Bullard-Dunn, decapagem anódica e decapagem com condutor central.

Na Usiminas são utilizados os processos de decapagem mecânica e química. Na mesma linha, antes de passar a bobina pelo banho de  $HCl$ , esta passa por rolos de curvatura, ou por um laminador "Skin-pass", que geram fissuras na camada de óxido, facilitando o trabalho da decapagem química.


Esta camada de carepa é composta do óxido  $FeO$ , em maior proporção e em contato com o metal base, em seguida vem a camada de  $Fe_3O_4$  e, por último, uma fina camada de  $Fe_2O_3$ .

As principais reações do processo de decapagem são:



Após o processo de decapagem, o produto das reações químicas é desviado para o processo de regeneração de ácido clorídrico. O ácido regenerado volta para o processo de decapagem mantendo o ciclo, assim evitando problemas com o seu descarte e diminuindo custos com menor aquisição de ácido novo. Outro produto da regeneração do ácido é o óxido de ferro, conhecido na indústria como "pó vermelho".

As principais reações para o processo de regeneração do ácido clorídrico são:



O processo de regeneração de ácido clorídrico consiste basicamente em alimentar um reator com o produto descartado da decapagem. Este reator é também chamado de "Roaster" e trabalha com temperaturas entre 600°C e 900°C. A alimentação é feita em forma de "spray" com o objetivo de diminuir suas partículas e facilitar a evaporação. Em poucos segundos é produzido ácido clorídrico gasoso e óxido de ferro sólido. O gás gerado no reator sai pelo topo e o óxido de ferro é depositado na parte de baixo do reator (Adham e Lee, 2009).




Figura 6.1: Diagrama esquemático do reator do processo de regeneração de ácido clorídrico

Ao sair pelo topo do reator, o gás passa ainda por um ciclone que garante a separação e recuperação de partículas de óxido que retornam para o reator. Este gás ainda passa por um pré-concentrador, reduzindo sua temperatura e eliminando os últimos traços de óxido de ferro. Em seguida este gás é lavado com água em uma coluna ("absorver") onde o ácido clorídrico é recuperado em sua forma líquida, sendo retirado na parte inferior da coluna de lavagem<sup>2</sup>. Existem ainda outras etapas do processo, mas que para o presente trabalho não têm relevância.

O diagrama esquemático do processo pode ser visto na figura 6.2.

<sup>2</sup>A descrição deste processo pode ser encontrada em [http://www.sms-siemag.at/Hydrometallurgy\\_Spray\\_Roaster\\_ARP.html](http://www.sms-siemag.at/Hydrometallurgy_Spray_Roaster_ARP.html)

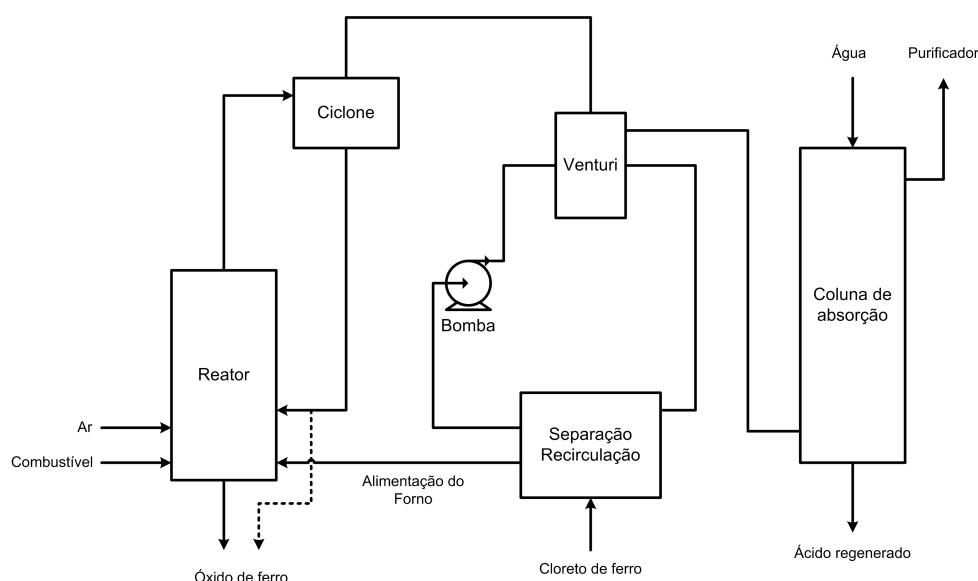


Figura 6.2: Diagrama esquemático do processo de regeneração de ácido clorídrico

A vazão de água na coluna também tem interferência de variações na bomba que impulsiona a água a partir de um tanque de armazenamento até o topo da coluna. O sistema atua na abertura da válvula para controlar a vazão de água da coluna.

### 6.3 Aplicação no Controle de Vazão de Água da Coluna de Lavagem do Gás HCl

O esquema de controle avaliado neste trabalho foi implementado no controle de vazão de água da coluna de lavagem do ácido gasoso. A vazão de água desta coluna interfere diretamente na concentração do ácido regenerado.

A planta de regeneração de ácido é controlada por um sistema dedicado da Yokogawa, o CS3000. O CS3000 é um modelo de DCS<sup>3</sup> e está sob responsabilidade do pessoal da instrumentação da Usiminas.

Para implementar a estratégia de controle neural adaptativa proposta foi utilizado o protocolo de comunicação OPC. O CS3000 trabalhou como um OPCServer e, como OPCClient, foi utilizado o Matlab instalado em um *notebook*. Esse acessava os dados do sistema via rede Ethernet TCP/IP (ver figura 6.3). Optou-se por esta arquitetura devido a sua facilidade de implementação,

<sup>3</sup>Distributed Control System



visto que o código do esquema de controle já estava desenvolvido. A alteração das funções para leitura e escrita das variáveis foi feita trocando-se as funções utilizadas na planta de neutralização de pH, testada anteriormente, pelas funções de leitura e escrita OPC.




Figura 6.3: Diagrama esquemático: conexão do *notebook* ao sistema Yokogawa

Nenhuma alteração na lógica de controle original foi necessária, apenas a adição de uma chave que fazia a seleção entre o código original do DCS ou o código do esquema de controle neural adaptativo implementado no Matlab (ver figura 6.4).

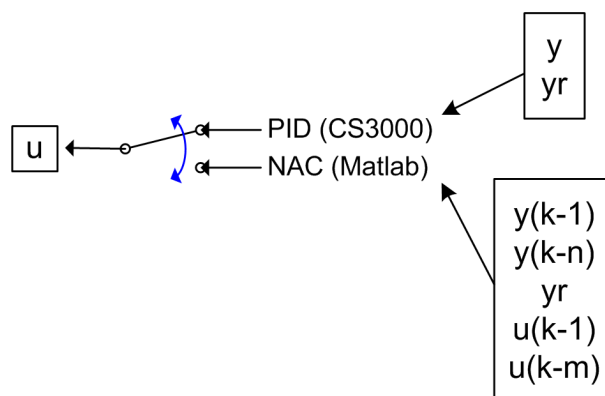


Figura 6.4: Chave de seleção entre o controlador convencional do CS3000 e o controlador neural adaptativo implementado no Matlab instalado em um notebook que acessa o sistema via rede Ethernet TCP/IP

O algoritmo completo da implementação do controle neural adaptativo híbrido indireto na malha de vazão de água da coluna de lavagem do ácido é mostrado na figura 6.5. Este diferencia-se do algoritmo apresentado na figura 4.6 apenas pela adição das fases de conexão e leitura OPC.

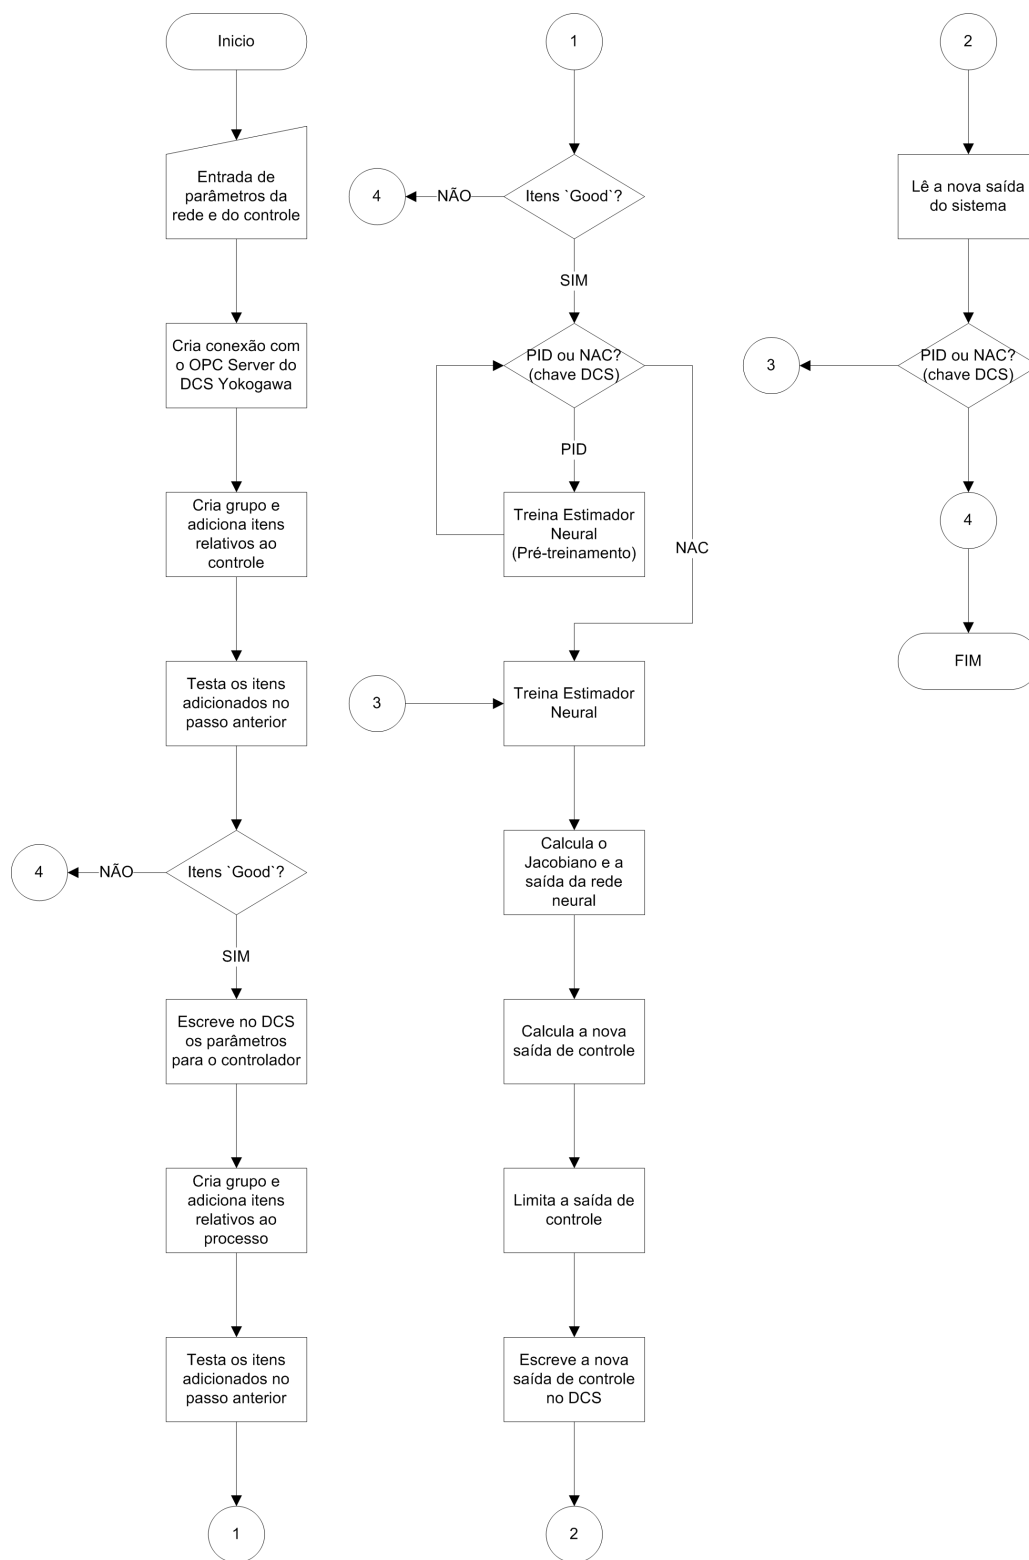


Figura 6.5: Fluxograma da estratégia de controle implementada no controle de vazão de água da coluna de lavagem de ácido da planta de regeneração de ácido clorídrico da Usiminas

### 6.3.1 Resultados Obtidos

O sistema de controle original, implementado pelo DCS, na malha de vazão de água da coluna é feito pelo algoritmo PID e utiliza um tempo de amostragem de 1 segundo. Com o objetivo de facilitar a análise da implementação com o controle neural adaptativo, foi realizada a coleta de dados com os resultados dos dois tipos de controladores com o mesmo sinal de referência. Os dados coletados com o resultado para o controlador PID original podem ser vistos na figura 6.6.




Figura 6.6: Resultado para o controlador PID. (a) Linha contínua: Sinal de vazão de água da coluna. Linha tracejada: Sinal de referência. (b) Sinal de controle (100% - valor de abertura da válvula)

Os dados para o controlador PID original foram coletados sem nenhum ajuste prévio deste. O controlador estava ajustado conforme o projeto original. Como o objetivo principal não era a substituição do controlador, mas sim verificar o funcionamento do controlador neural, nenhuma tentativa de melhorar o controlador original foi realizada.

A estratégia de controle neural adaptativa foi implementada com os seguintes parâmetros.

- Número de neurônios na camada escondida = 3
- Número de atrasos da entrada = 2
- Número de atrasos da saída = 2
- Tamanho da janela de treinamento = 10 amostras
- Tempo de amostragem = 3 segundos
- Tempo morto = 1 amostra

Todos estes parâmetros foram definidos empiricamente, com base na observação do funcionamento da planta e o resultado do controle original. O natural seria realizar uma pré-análise com métodos e técnicas apropriadas, conforme foi realizado para a planta de neutralização de  $pH$ , mas devido à indisponibilidade da planta ou, em outros momentos, devido à indisponibilidade do especialista, isto não foi possível.

Para o número de neurônios na camada escondida foi definido um número pequeno devido à baixa complexidade do sistema. O número de amostras na janela de treinamento e o número de atrasos da entrada e saída da planta também foram definidos com o mesmo critério. O tempo morto foi escolhido igual a 1 devido ao sistema não apresentar atraso de transporte. A atuação no ajuste de abertura da válvula tem efeito imediato na vazão de água da coluna.

Uma inspeção visual nos dados apresentados na figura 6.6 mostra que, durante o tempo de subida, tem-se de 60 a 80 amostras. Valor muito maior do que o geralmente indicado na literatura (Ji e Jong Kim, 2008; Clarke et al., 1987). Além disso, testes realizados no processo com o tempo de amostragem de 1 segundo não tiveram bons resultados. Assim, optou-se empiricamente alterar o tempo de amostragem para 3 segundos. Portanto, o controlador proposto foi implementado com um tempo de amostragem de 3 segundos.

Na figura 6.7 é apresentado o resultado do controle da malha de vazão realizado pelo controlador neural adaptativo.




Figura 6.7: Resultado para o Controle Neural Adaptativo. (a) Linha contínua: Sinal de vazão de água da coluna. Linha tracejada: Sinal de referência. (b) Sinal de controle (100% - valor de abertura da válvula)

O controlador neural adaptativo estudado neste trabalho apresentou resultado satisfatório. Percebe-se melhora significativa para o tempo de subida e uma menor variabilidade da saída em regime permanente. Para a transição do *setpoint* de 4000[l/h] para 4200[l/h] o tempo de subida para o controlador PID foi de 3,5 minutos, enquanto que para o controlador neural adaptativo foi de 1 minuto.

De forma a complementar a análise foram comparados também os índices IAE para os dois controladores. O controlador PID apresentou  $IAE = 2,66e4$ , enquanto que o controlador neural adaptativo apresentou  $IAE = 1,84e4$ , uma diferença de 44%. Uma diferença considerável, devido principalmente ao menor tempo de subida. O controlador neural manteve a saída do sistema mais próxima do sinal de referência durante o período do teste, demonstrando um melhor ajuste.

É possível ainda observar nos resultados apresentados que o sinal de controle para manter uma mesma vazão de saída foi diferente entre os dois testes apresentados. Esta diferença é devido à variações no processo e outros equipamentos da planta. Durante o primeiro patamar do sinal de referência é visível no gráfico apresentado na figura 6.6 que o sinal de controle estava ajustado perto de 81%, isto é, 19% de abertura da válvula. Para o controlador neural, o sinal de controle para o primeiro patamar do sinal de referência foi ajustado para perto de 75% (25% de abertura da válvula). Esta diferença foi verificada de um teste para outro, porém durante um mesmo teste, no caso para o teste com o controlador neural, apresentado na figura 6.7, durante o último patamar do sinal de referência percebe-se que houve variação do sinal de controle, porém o sinal de saída foi mantido, o que mostra a capacidade de adaptação do controlador.

O principal objetivo deste trabalho não foi a comparação entre os dois tipos de controladores. Para este fim o controlador PID deveria ter sido analisado e ajustado para sua melhor condição. Talvez ele esteja até com o melhor ajuste de parâmetros possível, mas este estudo não foi feito. O que é importante apresentar é que, independente de qualquer comportamento anterior, o resultado apresentado para o controlador neural foi satisfatório, sem muito esforço de projeto o controlador respondeu bem, principalmente, com relação ao tempo de subida.

Outra característica importante que pode ser destacada é que a estratégia foi implementada sem nenhum grande esforço preliminar para a determinação da ordem do identificador, do tempo de amostragem, do número de neurônios e do tamanho da janela de treinamento. Apesar da falta de uma análise detalhada do sistema para determinação dos parâmetros para o controlador, foi possível aplicar a estratégia e obter bons resultados, comparando-se a variabilidade e o tempo de subida para o sistema original, que atende ao processo dentro dos requisitos solicitados pela operação. Este fato vislumbra uma outra oportunidade de aplicação desta técnica e não somente para casos onde o sistema apresente alto grau de não-linearidade, que é a primeira característica

avaliada para a implementação de controladores adaptativos. A estratégia de controle estudada apresenta-se como uma boa opção para sistemas com malhas de controle pouco complexas, mas que sejam críticas para o processo.

# Capítulo 7

## Considerações Finais

### 7.1 Conclusões

Foi possível verificar durante o desenvolvimento do trabalho que os objetivos propostos foram alcançados. A implementação da técnica de *controle neural adaptativa híbrida indireta* foi implementada com sucesso no ambiente industrial e seus resultados são apresentados nesta dissertação como base para futuras implementações e novas pesquisas.

Outro objetivo proposto, o de investigar as reações do controlador variando-se alguns parâmetros como o número de neurônios, a ordem do identificador e o tamanho da janela de treinamento, foi também alcançado. Mostrou-se que o número de neurônios pode estar diretamente ligado com a complexidade, ou não-linearidade, do processo. Quanto mais não-linear é o processo, quanto mais complexo, maior o número de neurônios exigidos pelo identificador neural. Associado também à complexidade do processo, um maior volume de dados para o treinamento é necessário. Já para a ordem do sistema, acreditava-se que a própria rede neural fosse capaz de "eliminar" regressores pouco relevantes, mas o que foi percebido é que, admitindo-se um número excessivo de regressores, os que não participam efetivamente para a reprodução da dinâmica do sistema podem interferir negativamente.

A ideia de se ter um controlador auto-ajustável realmente empolga, mas não se deve esquecer de um detalhe: para sistemas complexos, que não foi o caso da planta industrial estudada, a capacidade de se adaptar, quando em operação, não elimina a necessidade inicial de se avaliar o projeto do controlador, ou seja, a fase de definição de seus parâmetros (o número de neurônios, o número de entradas para o identificador, o tempo de amostragem, o tamanho da janela de treinamento). Na verdade, a definição destes parâmetros pode ser mais complicada do que a



sintonia de um controlador convencional. Neste trabalho foi mostrado, para o caso da planta industrial, a implementação com sucesso da técnica de controle neural adaptativa sem uma análise detalhada para a definição dos parâmetros do controlador, mas nem sempre esta tarefa se apresenta simples assim, conforme foi visto para o caso da planta de neutralização de  $pH$ .

Deve-se avaliar com critério a real necessidade de uma técnica de controle adaptativa. Geralmente um controlador adaptativo deve ser escolhido para o caso onde uma planta apresenta alto grau de não-linearidade, a eficiência do controle é crítica e os distúrbios e variações do ambiente não são previsíveis. Para o controlador em questão, foi verificado que ele pode ser aplicado em sistemas com alto grau de não-linearidade, fora de regiões de altos ganhos. Apesar desta limitação, outra oportunidade de implementação foi verificada neste trabalho, a possibilidade de sua implementação em sistema menos complexos, mas que são de importância fundamental para o processo, ou seja, sistemas que, por exemplo, têm ligação direta com a qualidade do produto final. Neste caso pode-se melhorar a resposta de controle (diminuição do tempo de subida, diminuição da variabilidade) sem a necessidade de um procedimento de sintonia, nem antes e nem após o *startup*.

## 7.2 Sugestões para trabalhos futuros

Como propostas para trabalhos futuros, segue:

- avaliar a implementação do treinamento do identificador neural utilizando-se estratégias de poda com objetivo de se eliminar a fase preliminar de avaliação da ordem para o identificador e a fase de testes de tentativa e erro para adequação do número de neurônios da camada escondida, desta forma, simplificando a fase de projeto para o esquema de controle;
- desenvolver métodos para avaliação do tamanho da janela de treinamento;
- avaliar a utilização de algoritmos de treinamento com estratégias de regularização. Este tipo de algoritmo, como por exemplo, o *Levenberg-Marquardt* com regularização *Bayseana*, apresenta resultados muito bons para redes neurais estáticas;
- converter o código desenvolvido em Matlab para linguagem de PLC ou DCS, de forma que este possa ser utilizado diretamente num sistema dedicado e mais robusto do que um PC. Evita-se desta forma a falha no sistema de controle devido a problemas de rede ou ainda no hardware ou software do PC;

- 
- investigar a resposta do esquema de controle em sistemas que possuem atraso de transporte  $d > 1$ ;
  - investigar o comportamento da estratégia de controle para sistemas MIMO<sup>1</sup>.

---

<sup>1</sup>MIMO - *Multiple Input Multiple Output*



# Referências Bibliográficas

- Adetona, O., Sathananthan, S., e Keel, L. H. (2001). Robust nonlinear adaptive control using neural networks. Em *Proceedings of the American Control Conference*, Arlington, VA.
- Adham, K. e Lee, C. (2009). Minimizing fuel costs during thermal regeneration of the hydrochloric acid lixiviant. [http://www.hatch.ca/Non\\_Ferrous/articles/minimizing\\_fuelcost.pdf](http://www.hatch.ca/Non_Ferrous/articles/minimizing_fuelcost.pdf). Acesso em: 24 de maio de 2009.
- Aguirre, L. A. (2004). *Introdução à Identificação de Sistemas - Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG, 2ª edição.
- Aguirre, L. A. e Billings, S. A. (1995). Dynamical effects of overparametrization in non-linear models. *Physica D*, 80(1-2):26–40.
- Amaral, G. F. V. (2001). Uso de redes neurais e conhecimento a priori na identificação de sistemas dinâmicos não-lineares. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil.
- Astrom, K. J. e Wittenmark, B. (1994). *Adaptive Control*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA.
- Braga, A. P., Ludermir, T. B., e Carvalho, A. P. L. F. (2000). *Redes Neurais Artificiais - Teoria e Aplicações*. Livros Técnicos e Científicos Editora.
- Brinker, J. e Wise, K. (1996). Stability and flying quality robustness of a dynamic inversion aircraft control law. *Journal of Guidance, Control and Dynamics*, 19(6):1270–1277.
- Bugajski, D. e Enns, D. (1992). Nonlinear control law with application to high angle-of-attack flight. *Journal of Guidance, Control and Dynamics*, 15(3):761–767.
- Campos, R. C. C. (2007). Projeto e construção de planta piloto de neutralização de ph e proposta de metodologia para incorporação de informações auxiliares na identificação narx racional. Dissertação de Mestrado, Centro Universitário do Leste de Minas Gerais, Coronel Fabriciano.

- Carvalho, S. D. e Prado, M. L. M. (2008). Controle adaptativo auto-ajustável de um processo térmico. Em *XIII Congresso Latinoamericano de Control Automático*, Mérida, Venezuela.
- Clarke, D. W., Mohtadi, C., e Tuffs, P. S. (1987). Generalized predictive control - part ii. extensions and interpretations. *Automatica - Journal of the International Federation of Automatic Control*, 23(2):149–160.
- Corrêa, M. V., Aguirre, L. A., e Braga, A. P. (1999). Validação de modelos neurais identificados a partir de um sistema caótico. Em *IV Congresso Brasileiro de Redes Neurais*, pp. 152–158.
- Costa, M. A., Braga, A. P., e de Menezes, B. R. (2002). Improving neural networks generalization with new constructive and pruning methods. *Journal of Intelligent and Fuzzy Systems: Applications in Engineering and Technology*, 13:75–83.
- Cox, C., Mathia, K., Edwards, J., e Akita, R. (1996). Modern adaptive control with neural networks. Em *International Conference on Neural Networks Information Processing, ICONIP'96*, Hong Kong.
- Demuth, H., Beale, M., e Hagan, M. (2008). *Neural Network Toolbox 6 - Matlab User's Guide*.
- Doherty, S. K. (1999). *Control of pH in chemical processes using artificial neural networks*. Tese de Doutorado, Liverpool John Moores University., Liverpool, England.
- Egardt, B. (1979). *Stability of Adaptive Controllers*. Springer-Verlag New York, Inc., Secaucus, NJ, USA.
- Enns, D., Bugajski, D., Hendrick, R., e Stein, G. (1994). Dynamic inversion: an evolving methodology for flight control design. *Int. J. Control*, 59(1):71–91.
- Feil, B., Abonyi, J., e Szeifert, F. (2003). Model order selection of nonlinear input-output models - a clustering based approach. [http://www.fmt.vein.hu/softcomp/JPC-32-02\\_paper.pdf](http://www.fmt.vein.hu/softcomp/JPC-32-02_paper.pdf). Acesso em: 10 de agosto de 2009.
- Filho, O. G., Neto, A. D. D., Rego, J. B. A., e Damasceno, N. C. (2008). Controlador híbrido neural no controle de nível de uma planta industrial. Em *Anais do XVII Congresso Brasileiro de Automática (CBA 2008)*.
- Forsell, U. e Linkskop, P. (1997). Combining semi-physical and neural network modeling: an example of its usefulness. Em *11th International Federation of Automatic Control Symposium on System Identification (SYSID'97)*.

- Geman, S., Bienenstock, E., e Doursat, R. (1992). Neural network and the bias/variance dilemma. *Neural Computation*, 4:1–58.
- Hageman, J. J., Smith, M. S., e Stachowiak, S. (2003). Integration of online parameter identification and neural network for in-flight adaptive control. Technical report, NASA Dryden Flight Research Center.
- Hagiwara, M. (1990). Novel backpropagation for reduction of hidden units and acceleration of convergence using artificial selection. Em *International Joint Conference on Neural Networks of 1990 (IJCNN'90)*, pp. 1625–1630, Fukuoka, Japan.
- Hassibi, B., Stork, D. G., e Wolff, G. J. (1992). Optimal brain surgeon and general network pruning. Technical Report 9235, RICOH California Research Center.
- Haykin, S. (2001). *Redes Neurais: Princípios e Prática*. bookman, Porto Alegre, 2ª edição.
- Henrique, M. H., Lima, E. L., e Seborg, D. E. (2000). Model structure determination in neural networks models. *Chemical Engineering Science*.
- Hinton, G. E. (1989). Connectionist learning procedures. *Artificial Intelligence*, 40:185–234.
- Ioannou, P. e Fidan, B. (2006). *Adaptive Control Tutorial*. Society for Industrial and Applied Mathematics.
- Jain, L. C. e Fanelli, A. M. (2000). *Recent Advances in Artificial Neural Networks: Design and Applications*. The CRC Press International Series on Computational Intelligence.
- Ji, K. e jong Kim, W. (2008). Optimal bandwidth allocation and qos-adaptive control co-design for networked control systems. *International Journal of Control - Automation and Systems*, 6(4):596–606.
- Kalman, R. E. (1958). Design of a self optimizing control system. *Transactions of American Society Of Mechanical Engineers (ASME)*, pp. 468–478.
- Lane, S. H. e Stengel, R. F. (1988). Flight control design using non-linear inverse dynamics. *Automatica*, 24(4):471–483.
- Lee, A. W. e Hedrick, J. K. (1994). Application of approximate i/o linearization to aircraft flight control. *Journal of Dynamic Systems, Measurement and Control*, 116:429–436.
- Lopes, J. S., Popoff, L. H., Marcelo R.B.G. Vale, O. G. F., Araújo, F. M., e Maitelli, A. L. (2006). Um esquema de controle neural aplicado a um sistema de tanques acoplados utilizando controlador lógico programável. Em *Anais do XVI CBA*.

- Maitelli, A. L. e de Rezende, J. A. D. (2001). Um neurocontrolador com treinamento em tempo real aplicado a uma planta de temperatura. Em *Anais do V Simpósio Brasileiro de Automação Inteligente - SBAI*.
- Maitelli, A. L. e Filho, O. G. (2003a). Controlador híbrido indireto baseado em redes neurais - parte i: Desenvolvimento e implementação. Em *Anais do VI Simpósio Brasileiro de Automação Inteligente - SBAI*, pp. 183–188.
- Maitelli, A. L. e Filho, O. G. (2003b). Controlador híbrido indireto baseado em redes neurais - parte ii: Estabilidade e robustez. Em *Anais do VI Simpósio Brasileiro de Automação Inteligente - SBAI*, pp. 1067–1072.
- Muniz, L. A. R. (2004). *Controle Preditivo Adaptativo Aplicado a um Reator de Pirólise Operando em Regime Semi-Batelada*. Tese de Doutorado, Universidade Federal de Santa Catarina.
- Nardi, F. (2000). *Neural Network based Adaptive Algorithms for Nonlinear Control*. Tese de Doutorado, Georgia Institute of Technology.
- Narendra, K. S. e Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*, 1(1):4–27.
- Ng, G. W. (1997). *Application of Neural Networks to Adaptive Control of Nonlinear Systems*. Research Studies Pr Ltd.
- Norgaard, M. (2000). *Neural Network Based Control System Design TOOLKIT*. Department of Automation, Technical University of Denmark, 2ª edição.
- Norgaard, M., Ravn, O., Poulsen, N. K., e Hansen, L. K. (2001). *Neural Networks for Modelling and Control of Dynamic Systems*. Springer-Verlag.
- Ogata, K. (2003). *Engenharia de controle moderno*. Prentice Hall, 4ª edição.
- Osburn, P. V., Whitaker, H. P., e Kezer, A. (1961). New developments in the design of model reference adaptive control systems. Technical report, Institute of the Aerospace Sciences.
- Paganoto, S. F. (2008). Implementação de um neuro-controlador preditivo com otimização por seção Áurea aplicado em um processo de neutralização de ph. Dissertação de Mestrado, Centro Universitário do Leste de Minas Gerais.
- Popescu, D., Selisteanu, D., e Ionete, C. (2001). On adaptive and neural control of a robot arm. Technical report, University of Craiova.

- Praly, L. (1984). Robust model reference adaptive controllers - part i: Stability analysis. Em *23rd IEEE Conference on Decision and Control*, New York. IEEE Press.
- Ramirez-Beltran, N. D. e Jackson, H. (1999). Application of neural networks to chemical process control. *Computers and Chemical Engineering*, 37:387–390.
- Reed, R. (1993). Pruning algorithms - a survey. *IEEE Transactions on Neural Networks*, 4(5):740–747.
- Rezende, J. A. D. e Maitelli, A. L. (1999). Um estudo comparativo entre diferentes técnicas de otimização do treinamento de neurocontroladores. Em *Anais do IV Congresso Brasileiro de Redes Neurais*.
- Rhodes, C. e Morari, M. (1998). Determining the model order of nonlinear input/output systems directly from data. *AIChE Journal*, 44:151–163.
- Ribeiro, R. N. (2007). Utilização de redes neurais artificiais e tecnologia ft-nir para predição do número kappa em um processo kraft de cozimento de madeira em indústria de celulose. Dissertação de Mestrado, Centro Universitário do Leste de Minas Gerais.
- Schnitman, L. e de Barros Fontes, A. (1999). The basic ideas of neural predictive control. Em *Proceedings of the 7th Mediterranean Conference on Control and Automation (MED99)*.
- Singh, S. N. e Steinberg, M. (1996). Adaptive control of feedback linearizable nonlinear systems with application to flight control. *Journal of Guidance, Control and Dynamics*, 19(4):871–877.
- Takahashi, H. J. (2006). Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional. Dissertação de Mestrado, Centro Universitário do Leste de Minas Gerais.
- Vandoren, V. J. (2003). *Techniques for Adaptive Control*. Butterworth-Heinemann.
- Whitaker, H. P., Yamron, J., e Kezer, A. (1958). Design of model reference adaptive control systems for aircraft. Technical report, MIT - Instrumentation Laboratory.
- Widrow, B. e Walach, E. (2008). *Adaptive Inverse Control: A Signal Processing Approach*. IEEE Press.
- Ylén, J.-P. (2001). *Measuring, modelling and controlling the pH value and the dynamic chemical state*. Tese de Doutorado, Helsinki University of Technology.



# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)