EDWIN RED ESTOFANERO LARICO

**Identificação de modelos não-lineares com estruturas
NARX e Hammerstein-Wiener aplicados a uma
planta de neutralização de pH**

São Paulo
2020

EDWIN RED ESTOFANERO LARICO

**Identificação de modelos não-lineares com estruturas
NARX e Hammerstein-Wiener aplicados a uma
planta de neutralização de pH**

Versão Corrigida

(A versão original encontrase-se na unidade que aloja o Programa de Pós-Graduação)

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para a obtenção do título de Mestre em Ciências.

São Paulo
2020

EDWIN RED ESTOFANERO LARICO

**Identificação de modelos não-lineares com estruturas
NARX e Hammerstein-Wiener aplicados a uma
planta de neutralização de pH**

Versão Corrigida

(A versão original encontrase-se na unidade que aloja o Programa de Pós-Graduação)

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para a obtenção do título de Mestre em Ciências.

Área de Concentração:

3139 - Engenharia de Sistemas

Orientador:

Prof. Dr. Claudio Garcia

São Paulo
2020

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, _____ de _____ de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Estofanero Larico, Edwin Red

Identificação de modelos não-lineares com estruturas NARX e Hammerstein-Wiener aplicados a uma planta de neutralização de pH / E. R. Estofanero Larico -- versão corr. -- São Paulo, 2020.
122 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle.

1.Modelo não-lineares 2.NARX 3.Hammerstein-Wiener I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle II.t.

Dedicatória

A minha filha Safira e meus filhos Thiago e Russell, as pessoas que são agora minha inspiração para continuar estudando e trabalhando. Ao meus queridos pais Pedro e Lucrecia e aos meus irmãos Hugo e Susan.

AGRADECIMENTOS

Primeiramente agradeço ao meu orientador, Prof. Claudio Garcia, pela oportunidade de fazer meu mestrado na área de sistemas de controle e me dar a oportunidade de trabalhar no Laboratório Controle de Processos Industriais, além disso, agradeço também pelo apoio acadêmico e suporte quando eu precisava resolver minhas dúvidas.

Aos Profs. Fábio Fialho, Bruno Angélico, Ricardo Marques, José Jaime da Cruz, Darci Odloak, Fuad Kassab Junior, Diego Colón, Henrique Takachi Moriya pela amizade, paciência e tempo para conversar sobre alguns temas de controle que formavam parte da pesquisa.

A todos os meus colegas e amigos do LCPI da USP, Marco Stabilito, Walter Moreira Müller, Hadrien Desvages, Manuel Pérez, Victor Reyes, Waldomiro Monteiro, Fellipe Marques, Plinio Costa, Matheus Ferrazo, Diego Chavez, Aline Neves; aos meus colegas do Laboratório de Controle Aplicado da USP, Gabriel Pereira, Fabio Yukio, Arthur Castelo, Mateus Brugnoli pela amizade e apoio na área de controle; outros colegas da faculdade de Engenharia Elétrica como Carlos Prete, Josue Dantas, Walter Campos; amigos da Engenharia Mecânica como Gustavo Neto; amigos da Engenharia Química como Rafael Sencio, Matheus Guedes pelo apoio e revisão do meu trabalho.

Aos meus amigos Luis Timana, Alice Èvora, Isaac Gonzales, Maria Lucia, Vanderley Evangelista, Keiser Hurtado, Daniel Correia, Christiam Morales, Josue Avalos e Vanessa Gamero, pela amizade que me ofereceram aqui no Brasil, e que se tornarão meus melhores amigos.

Aos amigos feitos no CEPEUSP onde jogava futebol de quadra cada sábado, o qual serviu de distração semanal, aqui gostaria agradecer pela amizade a Mariana, Marco, Marcelo, Rodrigo, Hermano, Jainor, Bruno, Carlos, Leandro e Alonso. Em geral, quero agradecer pela amizade feita no Brasil com estudantes das diversas faculdades da USP.

Principalmente quero agradecer aos meus pais Pedro e Lucrecia, irmãos Hugo e Susan, pelo seu incentivo e apoio constante para terminar o mestrado. Finalmente, a Deus pela tranquilidade e paz que sempre está disposto a me oferecer quando eu preciso.

A todos, muito obrigado pela compreensão e apoio.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

Neste trabalho estuda-se a identificação não linear para encontrar os modelos matemáticos de três variáveis de processo (Temperatura, Nível e pH) de uma planta de neutralização de pH. São utilizadas estruturas não lineares do tipo NARX e Hammerstein-Wiener para descrever a dinâmica destas três variáveis e determinar qual destes modelos representa melhor cada variável a ser controlada. Esses modelos são avaliados usando a validação cruzada e comparados usando o índice FIT de cada modelo. Os experimentos de identificação foram realizados considerando cada variável como sistema SISO. A parte experimental deste trabalho foi dividida em duas partes: pré-teste e teste de identificação. O pré-teste foi realizado para cada uma das três variáveis em malha aberta e fechada, isto para obter a primeira aproximação do modelo da cada variável usando uma função de transferência de primeira ordem com atraso puro e posteriormente escolher uma função de transferência de cada variável e com isto calcular os parâmetros do sinal de excitação (tempo de amostragem, tempo de coleta de dados) a partir do tempo de acomodação e constante de tempo da função de transferência. Na segunda parte são realizados os testes de identificação não linear com sinais PRBS e GMN em malha aberta e fechada. Para o caso dos testes em malha fechada, foi utilizado um controlador PI para cada variável controlada. Neste trabalho também são apresentados os passos para realizar a identificação de um sistema não linear. Finalmente, os modelos NARX e Hammerstein-Wiener que foram obtidos foram satisfatórios, para as variáveis de temperatura e nível ficou melhor quando o sistema foi excitado com sinal PRBS e no caso da variável de pH com sinal GMN.

Palavras-Chave – Identificação de Sistemas não lineares, NARX, Hammerstein-Wiener, Planta de Neutralização de pH.

ABSTRACT

In this work it is studied the nonlinear identification to find the mathematical models of three process variables (Temperature, Level and pH) of a pH neutralization plant. The nonlinear structures NARX and Hammerstein-Wiener were used to describe the dynamics of these three variables and to determine the models that best represents each variable. These models are evaluated using cross-validation and compared using the FIT index of each model. The identification experiments were performed considering each variables as SISO system. The experimental part of this work was divided into two parts: pre-test and identification test. The pre-test was performed for each of the three variables in open and closed loop, to obtain the first approximation of the model of each variable using a first order plus dead time transfer function and then to choose a transfer function for each variable and thereby to design the excitation signal parameters (sampling time, data collection time) from the settling time and the transfer function time constant. In the second part, the nonlinear identification tests in open and closed loop using PRBS and GMN signals were performed. For the closed-loop tests, a PI controller was used for each controlled variable. In this work also are presented the steps to identify a nonlinear system. Finally, the NARX and Hammerstein-Wiener models that were obtained are satisfactory, for the temperature and level variables were better when the system was excited with PRBS signal and in the case of the pH variable with GMN signal.

Keywords – Nonlinear System Identification, NARX, Hammerstein-Wiener, pH neutralization plant.

LISTA DE FIGURAS

Figura 1	Sistema básico de controle por realimentação.	20
Figura 2	Hierarquia de Sistemas de Automação Industrial (ZHU, 2001). . . .	23
Figura 3	Curva de Titulação.	29
Figura 4	Diagrama esquemático da Planta Piloto de Neutralização de pH. . .	30
Figura 5	Arquitetura da rede da Planta Piloto de Neutralização de pH. . . .	32
Figura 6	Coleta de dados para Identificação de Sistemas.	34
Figura 7	Sinal PRBS.	36
Figura 8	Estimador de Parâmetros (EYKHOFF, 1974).	43
Figura 9	Diagrama de blocos para o Modelo NARX.	48
Figura 10	Fluxograma para obter o modelo NARX.	50
Figura 11	Modelo de Hammerstein.	51
Figura 12	Modelo de Wiener.	53
Figura 13	Modelo de Hammerstein-Wiener.	53
Figura 14	Fluxograma para obter o modelo HW.	56
Figura 15	Função pwlinear.	57
Figura 16	Função saturação.	58
Figura 17	Função <i>Deadzone</i>	59
Figura 18	Diagrama de blocos da malha aberta de Temperatura.	63
Figura 19	Degraus positivos na variável manipulada na malha aberta de Tem- peratura.	64
Figura 20	Degraus negativos na variável manipulada na malha aberta de Tem- peratura.	65
Figura 21	Diagrama de blocos da malha fechada de Temperatura.	67
Figura 22	Degraus positivos no SP da malha de Temperatura.	68

Figura 23	Diagrama de blocos da malha aberta de Nível.	69
Figura 24	Degraus na variável manipulada na malha aberta de Nível.	70
Figura 25	Diagrama de blocos da malha fechada de Nível.	71
Figura 26	Degraus no SP na malha de Nível.	72
Figura 27	Diagrama de blocos da malha aberta de pH.	73
Figura 28	Diagrama de blocos da malha fechada de pH.	73
Figura 29	Degraus no SP da malha de pH.	75
Figura 30	Sinal PRBS e seu espectro de potência para o teste de identificação não linear da malha aberta de temperatura.	80
Figura 31	Dados coletados de entrada e saída no teste de identificação não linear para a malha aberta de Temperatura com sinal PRBS.	81
Figura 32	Forma de onda e espectro de potência do sinal GMN para identificar a malha aberta de temperatura.	81
Figura 33	Dados coletados de entrada e saída no teste de identificação não linear para a malha aberta de Temperatura com sinal GMN.	82
Figura 34	Modelo de Hammerstein-Wiener para a malha aberta de Tempera- tura excitada com sinal PRBS.	83
Figura 35	Modelo de Hammerstein-Wiener para a malha aberta de Tempera- tura excitada com sinal GMN.	83
Figura 36	Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha aberta de Nível.	84
Figura 37	Dados coletados de entrada e saída no teste de identificação não linear com sinal PRBS para a malha aberta de Nível.	85
Figura 38	Forma de onda e espectro de potência do sinal GMN usado para identificar a malha aberta de Nível.	86
Figura 39	Dados coletados de entrada e saída no teste de identificação não linear com sinal GMN para a malha aberta de Nível.	86
Figura 40	Modelo de Hammerstein-Wiener para a malha aberta de Nível ob- tido com sinal PRBS.	88

Figura 41	Modelo de Hammerstein-Wiener para a malha aberta de Nível obtido com sinal GMN.	88
Figura 42	Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha aberta de pH.	89
Figura 43	Dados coletados de entrada e saída do teste de identificação não linear da malha aberta de pH com sinal PRBS.	89
Figura 44	Forma de onda e espectro de potência do sinal GMN usado para identificar a malha aberta de pH.	90
Figura 45	Dados coletados de entrada e saída para a malha aberta de pH do teste de identificação não linear com sinal GMN.	90
Figura 46	Modelo de Hammerstein-Wiener para a malha aberta de pH obtido com sinal PRBS.	91
Figura 47	Modelo de Hammerstein-Wiener para a aberta malha de pH obtido com sinal GMN.	92
Figura 48	Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha fechada de Temperatura.	93
Figura 49	Dados coletados de entrada e saída do teste de identificação não linear da malha fechada Temperatura com sinal PRBS.	93
Figura 50	Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de Temperatura.	94
Figura 51	Dados coletados de entrada e saída do teste de identificação não linear da malha fechada Temperatura com sinal GMN.	94
Figura 52	Modelo de Hammerstein-Wiener para a malha de Temperatura com sinal PRBS.	95
Figura 53	Modelo de Hammerstein-Wiener para a malha de Temperatura com sinal GMN.	95
Figura 54	Forma de onda e seu espectro de potência do sinal PRBS usado para identificar a malha fechada de Nível.	96
Figura 55	Dados coletados de entrada e saída do teste de identificação não linear com sinal PRBS para a malha fechada de Nível.	97

Figura 56	Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de Nível.	97
Figura 57	Dados coletados de entrada e saída do teste de identificação não linear com sinal GMN para a malha fechada de Nível.	98
Figura 58	Modelo de Hammerstein-Wiener da malha fechada de Nível com sinal PRBS.	99
Figura 59	Modelo de Hammerstein-Wiener da malha fechada de Nível com sinal GMN.	99
Figura 60	Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha fechada de pH.	100
Figura 61	Dados de entrada e saída coletados do teste de identificação não linear excitado com sinal PRBS para a malha fechada de pH.	100
Figura 62	Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de pH.	101
Figura 63	Dados coletados de entrada e saída do teste de identificação não linear da malha fechada de pH excitada com sinal GMN.	101
Figura 64	Modelo de Hammerstein-Wiener para a malha fechada de pH obtido com sinal PRBS.	103
Figura 65	Modelo de Hammerstein-Wiener para a malha fechada de pH obtido com sinal GMN.	104
Figura 66	Validação dos Modelos HW para a Temperatura.	107
Figura 67	Validação dos Modelos NARX para a Temperatura.	108
Figura 68	Validação dos Modelos HW para o Nível.	109
Figura 69	Validação dos Modelos NARX para o Nível.	110
Figura 70	Validação dos Modelos HW do pH.	111
Figura 71	Validação dos Modelos NARX do pH.	112

LISTA DE TABELAS

Tabela 1	Parâmetros da Planta de pH.	31
Tabela 2	Pontos de Operação da Planta Piloto de Neutralização de pH. . . .	32
Tabela 3	Regressores considerados para os modelos NARX.	49
Tabela 4	Estruturas nos blocos de entrada e saída dos modelos HW.	55
Tabela 5	Valores considerados para os graus de nb , nf e nk nos modelos HW.	55
Tabela 6	Faixa de operação das três variáveis a serem identificadas.	62
Tabela 7	Funções de transferência da Temperatura, obtidas do pré-teste de identificação em malha aberta.	66
Tabela 8	Parâmetros do controlador PI da malha fechada de Temperatura. .	67
Tabela 9	Funções de transferência da Temperatura, obtidas do pré-teste de identificação em malha fechada.	67
Tabela 10	Funções de transferência para a malha aberta de Nível obtidas do pré-teste de identificação.	70
Tabela 11	Parâmetros do controlador PI da malha fechada de Nível.	71
Tabela 12	Funções de transferência para a malha de Nível obtidas do pré-teste de identificação.	71
Tabela 13	Parâmetros do controlador PI da malha fechada de pH.	74
Tabela 14	Funções de transferência obtidas no pré-teste de identificação da malha fechada de pH.	76
Tabela 15	Cálculo da duração do experimento para a identificação não linear das três variáveis do processo.	77
Tabela 16	Cálculo do período de amostragem para a identificação não linear das três variáveis do processo.	77
Tabela 17	Cálculo do mínimo tempo de <i>bit</i> para a identificação não linear das três variáveis do processo.	78

Tabela 18	Duração dos experimentos para identificação e validação do modelos não lineares para as três variáveis em malha aberta.	79
Tabela 19	Parâmetros do teste de identificação não linear da malha aberta de Temperatura com sinal PRBS.	80
Tabela 20	Parâmetros do teste de identificação não linear da malha aberta de Temperatura com sinal GMN.	81
Tabela 21	Parâmetros do teste de identificação não linear da malha aberta de Nível com sinal PRBS.	84
Tabela 22	Parâmetros do teste de identificação não linear da malha aberta de Nível com sinal GMN.	86
Tabela 23	Parâmetros do teste de identificação não linear da malha aberta de pH com sinal PRBS.	89
Tabela 24	Parâmetros do teste de identificação não linear da malha aberta de pH com sinal GMN.	90
Tabela 25	Parâmetros do teste de identificação não linear da malha fechada de Temperatura com sinal PRBS.	92
Tabela 26	Parâmetros do teste de identificação não linear da malha fechada de Temperatura com sinal GMN.	94
Tabela 27	Parâmetros do teste de identificação não linear da malha fechada de Nível com sinal PRBS.	96
Tabela 28	Parâmetros do teste de identificação não linear da malha fechada de Nível com sinal GMN.	97
Tabela 29	Parâmetros do teste de identificação não linear da malha fechada de pH com sinal PRBS.	100
Tabela 30	Parâmetros do teste de identificação não linear da malha fechada pH com sinal GMN.	101
Tabela 31	Fits dos modelos de Hammerstein-Wiener para as três variáveis em malha aberta e em malha fechada.	105
Tabela 32	Fits dos modelos NARX para as três variáveis em malha aberta e em malha fechada.	106

LISTA DE SIGLAS

AIC	Critério de informação de Akaike (<i>Akaike information criterion</i>)
CSTR	Reator Tanque Agitado Contínuo (<i>Continuous Stirred Tank Reactor</i>)
ERR	Taxa de redução de erro (<i>Error Reduction Ratio</i>)
FIR	Resposta finita ao impulso (<i>Finite Impulse Response</i>)
FPE	Critério baseado no erro de predição (<i>Final Prediction Error</i>)
FOPDT	Sistema de Primeira Ordem mais tempo morto (<i>First Order Plus Dead Time</i>)
GMN	Generalized Multiple Noise
HW	Modelo não linear Hammerstein-Wiener
INL	Identificação não linear
LCPI	Laboratório de Controle de Processos Industriais
MIMO	Sistema com múltiplas entradas e múltiplas saídas (<i>Multi-input Multi-output</i>)
MISO	Sistema com múltiplas entradas e uma saída (<i>Multi-input single-output</i>)
MNL	Modelo não linear
MPC	Controle preditivo baseado em modelo (<i>Model-based Predictive Control</i>)
MQ	Mínimos Quadrados
MQO	Mínimos Quadrados Ortogonais
MSE	Erro Quadrático médio (<i>Mean Squared Error</i>)
NARMAX	Modelo não linear auto-regressivo, de média móvel e entradas exógenas (<i>Nonlinear Auto-Regressive Moving Average with exogenous inputs</i>)
NARX	Modelo não linear auto-regressivo, com entradas exógenas (<i>Non-linear Auto-Regressive with exogenous inputs</i>)
OPC	Plataforma aberta de comunicação (<i>Open Platform Communications</i>)
PID	Controlador Proporcional, Integral e Derivativo

PRBS	Sequência binária pseudo-aleatória (<i>Pseudo-Random Binary Signal</i>)
PTI	Pré-Teste de Identificação
PTIMA	Pré-Teste de Identificação em Malha Aberta
PTIMF	Pré-Teste de Identificação em Malha Fechada
SDCD	Sistema Digital de Controle Distribuído
SISO	Uma entrada, uma saída (Single-Input, Single-Output)
TAS	Tanque de Ácido Secundário
TASI	Tanque de Ácido Secundário Intermediário
TINL	Teste de Identificação não linear
TINLMA	Teste de Identificação não linear em Malha Aberta
TINLMA-PRBS	Teste de Identificação não linear em Malha Aberta excitado com sinal PRBS
TINLMF	Teste de Identificação não linear em Malha Fechada
TINLMF-GMN	Teste de Identificação não linear em Malha Fechada excitado com sinal GMN
TR	Tanque de reação
TBB	Tanque de Base para Bomba
TAP	Tanque de Ácido Principal
TAPI	Tanque de Ácido Principal Intermediário
USP	Universidade de São Paulo

LISTA DE SÍMBOLOS

$X(i)$	Vetor de dados coletados
θ	Vetor de parâmetros a estimar
φ^T	Vetor de regressão composto pelas entradas e saídas medidas até o instante $t - 1$
ξ	Vetor de resíduos
n_b	Ordem do numerador do modelo linear <i>Output Error</i>
n_f	Ordem do denominador do modelo linear <i>Output Error</i>
n_k	Ordem do atraso do modelo linear <i>Output Error</i>
n_u	Máximo atraso entre os regressores de entrada
n_y	Máximo atraso entre os regressores de saída
n_θ	Número de parâmetros do modelo identificado
$u(t)$	Entrada dos sistemas no domínio temporal
$u(k)$	Entrada dos sistemas no instante k
$y(t)$	Saída dos sistemas no domínio temporal
$y(k)$	Saída dos sistemas no instante k
$v(t)$	Ruído branco no domínio temporal
$\xi(k)$	Resíduos no instante k
$H(s)$	Função de transferência no domínio do tempo
K	Ganho estático
τ	Constante de tempo
T_s	Intervalo de amostragem
T_b	Tempo de bit
t_s	Tempo de acomodação
T_e	Duração do experimento
T_{sw}	Período de chaveamento
$\Phi_u(\omega)$	Espectro de potência do sinal de excitação
$\mathbb{R}$	Conjunto de números reais
$\mathbb{Z}$	Conjunto de números inteiros

SUMÁRIO

1	Introdução	20
1.1	Objetivos	21
1.2	Motivação	21
1.3	Estrutura da Dissertação	23
1.4	Revisão Bibliográfica	24
1.4.1	Planta de Neutralização de pH	24
1.4.2	Identificação de Sistemas	25
1.4.3	Estruturas não lineares	26
2	Processo de Neutralização de pH	28
2.1	Definição de pH	28
2.2	A curva de titulação	29
2.3	Descrição do Processo	29
2.4	Parâmetros da Planta Piloto de Neutralização de pH	31
2.5	Sistema de Controle e aquisição de dados	31
2.6	Dinâmica da Planta	32
3	Identificação de Sistemas Não Lineares	33
3.1	Definição dos parâmetros do experimento	35
3.1.1	Sinais de excitação	35
3.1.1.1	Sinal PRBS	36
3.1.1.2	Sinal GMN	36
3.1.2	Procedimento para o projeto de sinais de excitação	37

3.1.2.1	Ter conhecimento <i>a priori</i> sobre o comportamento dinâmico da planta	37
3.1.2.2	Calcular a amplitude do sinal de excitação	37
3.1.2.3	Calcular a frequência máxima e mínima do sinal de excitação	38
3.1.2.4	Estabelecer a duração mínima do experimento	38
3.1.2.5	Cálculo do intervalo de amostragem	38
3.1.2.6	Cálculo da duração mínima em cada patamar do sinal de excitação	39
3.2	Normalização dos dados coletados	39
3.3	Determinação da estrutura	40
3.3.1	Taxa de Redução de Erro - ERR	40
3.3.2	Critério de parada do crescimento da ordem do modelo	41
3.3.2.1	Critério de Informação de Akaike (AIC)	41
3.3.2.2	Critério de Informação Bayesiano (BIC)	42
3.4	Estimação de Parâmetros	42
3.4.1	Método dos Mínimos Quadrados	43
3.5	Validação do modelo	44
3.5.1	Validação estatística	45
3.5.2	Validação dinâmica	45
3.5.3	Análise de Resíduos	46
4	Estruturas Não Lineares	47
4.1	Modelo NARX	47
4.2	Modelo de Hammerstein	51
4.3	Modelo de Wiener	52
4.4	Modelo de Hammerstein-Wiener	52
4.4.1	Função <i>pwlinear</i>	57

4.4.2	Função <i>Sigmoidnet</i>	57
4.4.3	Função Saturação	58
4.4.4	Função <i>Deadzone</i>	58
4.4.5	Função <i>Wavenet</i>	59
5	Experimentos e Resultados	61
5.1	Pré-testes de Identificação	62
5.1.1	Pré-teste de Identificação da Malha de Temperatura	62
5.1.1.1	Pré-teste de Identificação da malha aberta de Temperatura	63
5.1.1.2	Pré-teste de Identificação da malha fechada de Temperatura	67
5.1.2	Pré-teste de Identificação da Malha de Nível	69
5.1.2.1	Pré-teste de Identificação da malha aberta de Nível	69
5.1.2.2	Pré-teste de identificação da malha fechada de Nível	71
5.1.3	Pré-teste de Identificação da Malha de pH	73
5.1.3.1	Pré-teste de Identificação da malha aberta de pH	73
5.1.3.2	Pré-teste de Identificação da malha fechada de pH	73
5.2	Testes de Identificação não linear em Malha Aberta	79
5.2.1	Identificação não linear em malha aberta de Temperatura	79
5.2.1.1	Modelos NARX da malha aberta de temperatura	81
5.2.1.2	Modelos de Hammerstein-Wiener da malha aberta de temperatura	83
5.2.2	Identificação não linear para a malha aberta de Nível	84
5.2.2.1	Modelos NARX da malha aberta de Nível	87
5.2.2.2	Modelos de Hammerstein-Wiener da malha aberta de Nível	87
5.2.3	Identificação não linear para a malha aberta de pH	88
5.2.3.1	Modelos NARX para a malha aberta de pH	89
5.2.3.2	Modelos de Hammerstein-Wiener da malha aberta de pH .	91

5.3	Testes de Identificação não linear em Malha Fechada	92
5.3.1	Identificação não linear para a malha fechada de Temperatura . . .	92
5.3.1.1	Modelos NARX para a malha fechada de Temperatura . .	94
5.3.1.2	Modelos de Hammerstein-Wiener da malha fechada de temperatura	95
5.3.2	Identificação não linear para a malha fechada de Nível	96
5.3.2.1	Modelos NARX para a malha fechada de Nível	97
5.3.2.2	Modelos de Hammerstein-Wiener para a malha fechada de Nível	99
5.3.3	Identificação não linear para a malha fechada de pH	99
5.3.3.1	Modelos NARX para a malha fechada de pH	102
5.3.3.2	Modelos de Hammerstein-Wiener da malha fechada de pH	103
5.4	Validação dos Modelos não lineares	104
5.4.1	Validação dos modelos da malha de Temperatura	105
5.4.2	Validação dos modelos da malha de Nível	105
5.4.3	Validação dos modelos da malha de pH	106
5.4.4	Resultados das validações	106
6	Conclusões e trabalhos futuros	113
6.1	Pré-testes de Identificação	113
6.2	Identificação não linear	113
6.3	Modelos não lineares	114
6.4	Trabalhos Futuros	115
	Referências Bibliográficas	116
	Apêndice A – Cálculo de concentrações	121
A.1	Cálculo da concentração de Solução Base	121
A.2	Cálculo da concentração da Solução Ácida	121

1 INTRODUÇÃO

A partir da década dos anos de 1970, a teoria de Identificação de Sistemas foi sendo desenvolvida como parte da teoria de controle e se tornou uma ferramenta com algoritmos e métodos que podem ser aplicados a diferentes sistemas e processos industriais (ALVARADO, 2013), (RODRIGUEZ, 2015). Uma das primeiras teorias apresentadas sobre a identificação de modelos caixa-preta foi baseada no princípio de máxima verossimilhança (ASTROM; BOHLIN, 1965). A identificação da estrutura e teste de não linearidade de um sistema dinâmico não linear foi desenvolvida para encontrar os termos corretos e a estrutura do modelo (HABER; UNBEHAUEN, 1990).

Nesta pesquisa, considera-se o processo como sendo uma planta processadora industrial, que tem por objetivo produzir um material ou produto. Dentro deste âmbito, são consideradas as indústrias químicas, petroquímicas, farmacêuticas, alimentícias, de papel, de vidro, de metais e de cimento (ZHU, 2001).

Um processo industrial não linear de controle SISO com realimentação da saída basicamente está conformado por uma planta a ser controlada e um controlador atuando para atingir o valor de referência desejado. Um controlador não linear pode ser projetado usando técnicas de controle baseadas em modelos não lineares, mas o modelo do processo normalmente não é conhecido, portanto é necessário identificá-lo. Na Figura 1, representa-se um sistema de realimentação básico, onde se mostra um processo e um controlador.

Figura 1: Sistema básico de controle por realimentação.

A aplicação da teoria de identificação de sistemas não lineares pode-se estender a outras áreas além da indústria, tais como biologia, economia, etc. No contexto de Sistemas de Controle, a aplicação dos modelos não lineares é a implementação de controladores não lineares baseados em modelos, um exemplo é o controlador preditivo não linear (GOMEZ; JUTAN; BAEYENS, 2004).

1.1 Objetivos

Este trabalho tem como principal objetivo identificar os modelos não lineares NARX e Hammerstein-Wiener para três variáveis (Temperatura, Nível e pH) de uma planta de neutralização de pH. Este objetivo principal conduz aos seguintes objetivos específicos:

- Aplicar os conceitos de identificação não linear para realizar os testes experimentais;
- Explorar as ferramentas e técnicas de identificação não linear para conseguir um bom modelo não linear;
- Comparar as funções de transferência dos pré-testes para cada variável controlada em malha aberta e malha fechada e escolher a que seja mais representativa para a dinâmica dessa variável. E a partir dessa função de transferência projetar o sinal de excitação para identificar o sistema;
- Apresentar os modelos não lineares NARX e Hammerstein-Wiener;
- Realizar a validação cruzada dos modelos não lineares obtidos;
- Comparar os modelos obtidos e identificar qual representa melhor o processo.

1.2 Motivação

A principal motivação para realizar este trabalho foi o desejo de obter modelos não lineares. Surgiu então a questão de qual modelo não linear representaria melhor o comportamento dinâmico dos sistemas a serem controlados, então foi necessário revisar a literatura de Identificação de Sistemas não lineares e verificou-se que é uma área de pesquisa com bastantes publicações como (ZHU, 2001), (GOMEZ; JUTAN; BAEYENS, 2004), (BASSO et al., 2005), (BILLINGS, 2013).

Como a maioria dos processos industriais são não lineares e quando os controladores lineares não forem suficientes para atingir os requisitos de desempenho, justifica-se implementar controladores não lineares, porém, é necessário obter os modelos não lineares desses processos para projetar os controladores não lineares (GARCIA; MORARI, 1982), (CAMACHO; BORDONS, 1999). O desenvolvimento de sistemas não lineares combinado com os avanços em *hardware* e *software* dos sistemas de controle tornaram realidade a implementação de estratégias de controle para os processos não lineares, e justamente para os processos químicos que apresentam retardos, restrições, e incertezas nos modelos (BEQUETTE, 1991).

Uma planta de neutralização de pH representa na indústria um caso em que é possível observar o comportamento de um sistema não linear. Usando a Identificação de Sistemas não lineares, pode-se modelar este processo. Existem diferentes técnicas de controle não linear baseadas no modelo do sistema, tais como MPC não linear e adaptativo; se o modelo discreto é transformado em uma equação de estados, então para esses sistemas podem ser usadas técnicas de controle não linear como Linearização por Realimentação (MCAVOY, 1972b).

O desenvolvimento desta pesquisa tem o objetivo de mostrar como são feitos na prática os testes de identificação com sistemas de temperatura, nível e pH, mostrando o procedimento para identificar os modelos não lineares. No momento de realizar testes de identificação de sistemas, um dos principais problemas que se apresenta é não se ter um conhecimento detalhado do sistema. Para se ter uma versão simplificada do modelo de um sistema é necessário fazer pré-testes de identificação com a finalidade de conhecer a dinâmica do sistema, para depois definir os principais parâmetros da fase de identificação, tais como amplitude do sinal de excitação, duração de experimento, intervalo de amostragem, etc. Na etapa do pré-teste também se pode utilizar dados históricos e conhecimento dos engenheiros e técnicos da planta para estimar parâmetros como o ganho e o tempo de acomodação.

Em processos industriais, como na indústria do petróleo, gás, cimento e mineração, é relevante controlar as variáveis do processo em valores desejados, isto para melhorar a eficiência da planta em todo seu conjunto. Para o caso do processo de pH, devido à sua não linearidade e sua alta sensibilidade a perturbações, a neutralização de pH não é obtida com rapidez e precisão. Porém, se faz necessário identificar os modelos não lineares para implementar controladores baseados nesses modelos.

Outra razão pela qual se estudam os modelos não lineares, é que os controladores

lineares são sintonizados para trabalhar em torno de uma faixa limitada de operação e eventuais mudanças nestas condições acabam comprometendo o desempenho do sistema. Porém, para processos cujo comportamento mude significativamente de acordo com o ponto de operação, uma opção é recorrer a controladores não lineares, para com isto aumentar a faixa de operação do processo e melhorar o controle.

Na Figura 2 mostra-se a hierarquia de Sistemas de Automação Industrial. No nível mais baixo, corresponde à área de Instrumentação e Controle Regulatório, onde aloca-se controladores clássicos como o PID e *ON/OFF*, no nível de Controle Avançado do Processo aloca-se o controlador MPC não linear (ZHU, 2001).

Figura 2: Hierarquia de Sistemas de Automação Industrial (ZHU, 2001).

1.3 Estrutura da Dissertação

O trabalho está estruturado da seguinte forma:

O Capítulo 2 descreve o processo de neutralização de pH, indicando os parâmetros químicos que foram considerados para entender o processo, identificar os principais elementos e como é realizada a coleta de dados. Também descreve os processos de controle com os quais se vai trabalhar.

O Capítulo 3 apresenta os modelos não lineares que são usados para identificar o sistema. Também são apresentados os critérios para escolher a estrutura do modelo, estimar os seus parâmetros e realizar sua validação.

O Capítulo 4 apresenta as diferentes estruturas de modelos não lineares NARX e Hammerstein-Wiener.

O Capítulo 5 descreve como foram realizados os experimentos, os cálculos que foram feitos para a excitação do processo, coleta de dados e identificação dos modelos não lineares, critérios para escolha dos regressores não lineares e termos associados a cada um deles.

Finalmente, o Capítulo 6 apresenta as conclusões dos experimentos realizados, qual modelo foi o melhor para cada variável e trabalhos que poderiam ser realizados posteriormente.

1.4 Revisão Bibliográfica

A revisão bibliográfica baseia-se principalmente em três partes:

- Planta de Neutralização de pH;
- Identificação de Sistemas;
- Estruturas não lineares.

1.4.1 Planta de Neutralização de pH

Para compreender o processo de neutralização de pH foram revisados os trabalhos de (MCAVOY; HSU; LOWENTHAL, 1972a), (JACOBS; HEWKIN; WHILE, 1980), (JUTILA; ORAVA; SALMELIN, 1981), (JUTILA; VISALA, 1984), (WRIGHT; SOROUGH; KRAVARIS, 1991a), (HENSON; SEBORG, 1994), (SEBORG, 1994), (GUSTAFSSON et al., 1995), (IBRAHIM, 2008), (MARQUES, 2014), e na interpretação dos modelos matemáticos e a simulação do processo (SUNG; LEE, 1995b), (GARCIA, 2005). Também têm sido referenciados nas últimas décadas os trabalhos de (SEBORG; EDGAR; MELLICHAMP, 2010), (ABDULLAH; KARSITI; IBRAHIM, 2012), (FAVARO, 2012), que estudam os modelos de processos químicos industriais, descrevendo as reações que acontecem no reator de neutralização, explicando os balanços de massa que atuam nele e identificando três hipóteses que devem ser assumidas em um reator contínuo de tanque agitado (CSTR): 1) Os reagentes no reator devem ser misturados corretamente; 2) a densidade dos produtos envolvidos nas reações deve ser constante; e 3) o volume do líquido contido no CSTR deve ser constante.

O problema de controle de um processo de neutralização de pH é uma questão de modelamento químico. Modelos não lineares para o processo de neutralização do pH são válidos para reações ácido-base em soluções de água e são descritas a partir de princípios básicos, e um modelo não-paramétrico é introduzido para processos com composição desconhecida (GUSTAFSSON; WALLER, 1992). O processo de neutralização de pH é bem conhecido na literatura como um processo altamente não linear (MCAVOY; HSU; LOWENTHAL, 1972a), (GUSTAFSSON, 1982), (PAJUNEN, 1987), (SUNG; LEE, 1995a), (WRIGHT; KRAVARIS, 2001), (IBRAHIM, 2008). A não linearidade é considerada pela definição logarítmica do pH, assim como também as relações associadas ao ponto do equilíbrio quando as soluções ácida e básica reagem.

1.4.2 Identificação de Sistemas

Os conceitos ou a teoria sobre identificação de sistemas que foram consideradas para este trabalho foram tomadas de (SODERSTROM; STOICA, 1989), (ZHU, 2001), (BILLINGS, 2013), (AGUIRRE, 2015). Esses autores definem os métodos para fazer os testes de identificação, escolha dos termos da estrutura, escolha de regressores e como realizar a validação dos modelos identificados.

Na realização dos testes de identificação foram considerados os critérios para o projeto desses testes apresentados em (PAJUNEN, 1987), (ZHU, 2001), (ALVARADO, 2013), (AGUIRRE, 2015). Também foram estudados os trabalhos referentes à implementação das estruturas de identificação como em (LEONTARITIS; BILLINGS, 1985a), (LEONTARITIS; BILLINGS, 1985b), (HABER; UNBEHAUEN, 1990), (VARGAS, 1999). De (KURAMOTO, 2012) foi considerado um procedimento de seleção de sinais de excitação.

De (EYKHOFF, 1974) foi usada a teoria e definições dos métodos de estimação de parâmetros, estimadores por mínimos quadrados, análise de regressão, assim como também os critérios de observação de resultados nos experimentos realizados para identificar um modelo matemático. Em (DIAZ; DESROCHERS, 1988) um algoritmo é apresentado que produz um modelo polinomial para um sistema discreto não linear. O algoritmo faz uso dos dados coletados de entrada e saída do sistema e é aproximado por uma equação diferencial.

De (LJUNG, 1999) foram considerados os conceitos de identificação de sistemas não lineares, os métodos de estimação de parâmetros, projeto de experimentos, critério de seleção de identificação, validação de modelos e, finalmente, como usar a Toolbox do Matlab para realizar testes de identificação.

De (ZHU, 2001) foi aplicada a metodologia para fazer o pré-teste de identificação e o teste de identificação, isto é, como escolher a duração do experimento, seleção das entradas e saídas de um processo, como fazer os testes preliminares, escolher o sinal de excitação a ser utilizado no experimento, como escolher o período de amostragem de acordo com a dinâmica do processo ou sistema. Também ele indica como escolher a duração do experimento, colocando alguns critérios gerais. Nesta referência também são definidas as estruturas de modelos Wiener, Hammerstein e Hammerstein-Wiener.

Em (AGUIRRE, 2015), apresenta-se também o procedimento para realizar os testes de experimentação para identificar os modelos não lineares NARX, Hammerstein-Wiener. Além disso, ele explica o funcionamento e as diferenças entre os métodos de estimação de parâmetros por mínimos quadrados.

Finalmente, na fase de validação de modelos, foi considerado o trabalho de (ALVARADO, 2017), que apresentou o desenvolvimento de um método de validação de modelos, tendo como ferramentas de avaliação os métodos estatísticos, avaliações dinâmicas e análise da robustez do modelo.

1.4.3 Estruturas não lineares

Os conceitos básicos dos sistemas não lineares, foram consultados nos trabalhos de (NIJMEIJER; SCHAFT, 1990), (SLOTINE; LI, 1991).

A definição da estrutura de modelo não linear **NARX** encontra-se em (LEONTARITIS; BILLINGS, 1985b), (PRÖLL; KARIM, 1994), (BILLINGS, 2013), (AGUIRRE, 2015). Como uma aplicação da identificação de modelos não lineares, foi consultado o trabalho de (ZANABRIA, 1997), que identificou a planta de neutralização de pH usando o método de invariantes de reações, indicando os modelos NARX com a diferença que o experimento foi realizado com simulações e não em uma planta real. Em (JERÔNIMO, 1998) apresentou-se os modelos NARX polinomiais. Os resultados são analisados e características ligadas às não linearidades do pH e do nível de líquido são apresentadas. O trabalho de (JERÔNIMO, 1998) baseou-se em resultados de simulação e serviu com um guia de como coletar dados de identificação, obter e validar os modelos.

De (BASSO et al., 2005) foi revisado o critério para seleção de estrutura de um modelo NARX de uma turbina a gás da marca General Electric - Nuovo Pignone, onde a entrada do modelo é a vazão de combustível e a saída a velocidade da turbina.

Para o caso das estruturas de modelos Hammerstein, Wiener e Hammerstein-Wiener

foram consultados os trabalhos de (NARENDRA; GALLMAN, 1966), (HABER; UNBEHAUEN, 1990), (ZHU, 2001), (GOMEZ; JUTAN; BAEYENS, 2004), (ROMANO, 2010), (AGUIRRE, 2015).

2 PROCESSO DE NEUTRALIZAÇÃO DE PH

Neste capítulo define-se o pH, a curva de titulação e explica-se o funcionamento do processo de neutralização de pH. Apresentam-se os parâmetros de funcionamento da planta e, finalmente, explica-se como é realizada a coleta de dados.

2.1 Definição de pH

O pH é o logaritmo negativo da atividade do íon de hidrogênio, em íons por litro.

$$pH = -\log [H^+] \quad (2.1)$$

A água pura pode-se dissociar em uma baixa proporção em íon de hidrogênio (H^+) e hidroxila (OH^-), como é descrito na seguinte equação:

O produto da concentração de íon de hidrogênio pela concentração de íons de hidroxila é chamado de produto iônico da água (K_w). Este produto tem um valor constante a 25°C de:

$$K_w = [H^+][OH^-] = 10^{-14} \quad (2.3)$$

Na água, para cada íon de hidrogênio, há um íon de hidroxila.

$$K_w = [10^{-7}][10^{-7}] = 10^{-14} \quad (2.4)$$

Da Equação (2.3) pode-se deduzir que as concentrações de hidrogênio e hidroxila são inversamente proporcionais, ou seja, o aumento de uma das concentrações implica na diminuição da outra. Igualmente, é possível concluir que a escala do pH vai tipicamente de 0 a 14 em dissolução aquosa, sendo ácidas as dissoluções com um pH menor que 7, básicas as que têm um pH maior que 7 e neutras as que têm um pH igual a 7, em que o dissolvente é a água.

2.2 A curva de titulação

A unidade primária de informação básica requerida para o projeto de sistemas de controle de pH é a curva de titulação, algumas vezes referida como a curva característica ou a curva de equalização. Esta curva representa o comportamento dinâmico ao adicionar uma solução básica sobre uma solução ácida, e permite observar a faixa de não linearidade perto do valor de neutralização. Na Figura 3 observa-se uma curva de titulação onde foi-se adicionando uma solução básica sobre outra solução ácida inicial de 30,00L, neste caso teve que se adicionar 14,55L para chegar a um valor de pH de 7,01 partindo de um pH de 2,44.

Figura 3: Curva de Titulação.

2.3 Descrição do Processo

A planta de neutralização de pH é composta basicamente de um Tanque de Ácido Principal (TAP), um Tanque de Ácido Principal Intermediário (TAPI), um Tanque de Ácido Secundário (TAS), um Tanque de Ácido Secundário Intermediário (TASI), um Tanque de Base para Bomba (TBB), um Tanque de Reação (TR) e uma bomba de solução básica (FZ-41). A Figura 4 apresenta um diagrama esquemático simplificado das três malhas de controle a serem estudadas na Planta Piloto de Neutralização de pH, (não aparecem os tanques TAS e TASI).

O processo tem dois circuitos de solução ácida e um circuito de solução básica até o tanque de reação (TR). O primeiro circuito de solução ácida preparada no TAP flui para o

Figura 4: Diagrama esquemático da Planta Piloto de Neutralização de pH.

TAPI. A solução contida no TAPI flui para o TR onde se realiza a reação química com a solução base proveniente do tanque TBB. O fluxo de vazão é permitido pelo acionamento da válvula solenoide (FV-31). A vazão do TAPI para o TR depende da abertura da válvula manual e é medida por um transmissor magnético de vazão (FIT-31). Excetuando-se as identificações dos instrumentos, as mesmas funcionalidades podem ser estendidas para o segundo circuito de solução ácida que vai desde o TAS e o Tanque de Ácido Secundário Intermediário (TASI).

Já a solução preparada no TBB flui para o TR através de uma bomba dosadora (FZ-41). O pH no TR é medido através de um sensor de pH e o transmissor de pH (AIT-40). A vazão da solução básica é ajustada através de um sinal de controle de 4-20mA, gerado pela saída do controlador de pH (AIC-41), com o objetivo de manter o pH no TR no valor de referência desejado.

Nesta planta tem-se variáveis analógicas de processo como temperatura, nível, vazão, pH e condutividade; além disso, tem-se também variáveis analógicas de controle como porcentagem de abertura de uma válvula de controle, porcentagem de dosagem de solução básica e porcentagem de potência fornecida a uma resistência elétrica.

2.4 Parâmetros da Planta Piloto de Neutralização de pH

Na Tabela 1, mostram-se os parâmetros relacionados ao tanque de reação e os valores de operação da Planta Piloto de Neutralização de pH do Laboratório de Controle de Processos Industriais da EPUSP. Mostram-se quatro colunas compostas de Variável, Símbolo, Valor Nominal e Unidade, respectivamente. Destaca-se que os testes ocorreram com vazão de ácido de 50 l/h.

Tabela 1: Parâmetros da Planta de pH.

Variável	Símbolo	Valor Nominal	Unidade
Vazão de ácido	Qa	50.0	l/h
Vazão de base	Qb	0.0-60.0	l/h
Vazão de saída	Qs	0-110.0	l/h
Concentração de ácido	$c1$	0.0056	mol/l
Concentração de base	$c2$	0.0186	mol/l
Volume no TR	V	0.062	m ³
Área da base do TR	A	0.1257	m ²
Altura do TR	h	0.5	m
Constante de dissociação	k_w	10^{-14}	mol/l

Fonte: Autor

2.5 Sistema de Controle e aquisição de dados

A operação da Planta Piloto se dá através de telas de supervisão configuradas em estações de operação, implementadas na plataforma proprietária da ABB®. Ademais, um servidor *Open Platform Communications* (OPC) possibilita a troca de informações entre a Planta Piloto e o MATLAB®.

Um Sistema Digital de Controle Distribuído (SDCD), da marca ABB®, modelo 800xA, é utilizado para realizar as funções de controle e aquisição de dados da planta através dos seus módulos de entrada e saída digitais e analógicos. Na Figura 5, observa-se a arquitetura de rede da planta de pH, composta principalmente de um Servidor de Aspectos, Servidor de Domínio, Servidor de Conectividade, uma rede Ethernet industrial de Controle, um SCDC da marca ABB, e as variáveis de medição e controle.

3 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES

Neste capítulo, descreve-se a teoria de Identificação de Sistemas não lineares. A identificação de sistemas procura obter modelos matemáticos que reproduzam o comportamento dinâmico de um processo, ela é realizada usando e analisando os dados de entrada e saída coletados (ASTROM; BOHLIN, 1965), (ZHU, 2001), (ALVARADO, 2013), (AGUIRRE, 2015). A teoria de sistemas não lineares é amplamente estudada na literatura. Uma das principais características dos sistemas não lineares é que eles não obedecem ao princípio da superposição (SLOTINE; LI, 1991), (KHALIL, 2002), (BILLINGS, 2013). Existem sistemas cujo comportamento dinâmico não podem ser expresso por meio de equações diferenciais ordinárias lineares. Neste caso, precisa-se modelos matemáticos não lineares (VIDYASAGAR, 1993).

Um dos primeiros trabalhos que tratou o problema de identificação de sistemas foi (EYKHOFF, 1974). Em (ASTROM; BOHLIN, 1965) cita-se que quando é aplicado o esquema de identificação, aparecem muitos problemas que são naturais da dinâmica do sistema ou processo a identificar. Estes podem ser:

- Qual é a precisão para estimar?
- O que acontece com a estimação ao incrementar o número de observações?
- Há alguma forma melhor de estimar os parâmetros do modelo?
- Quais sistemas são possíveis de se identificar?
- Qual é o critério para escolher um sinal de excitação?
- Qual seria a ordem da estrutura do modelo?
- O modelo obtido tem as mesmas características que o processo real?

O conceito de identificação de Sistemas está relacionado com a coleta de dados, determinação do intervalo de amostragem, tipo do sinal usado para excitar o processo, estrutura

do modelo, seleção das ordens para o modelo. Os dados coletados da identificação são obtidos através da medição simultânea da resposta na saída do processo $y(t)$ a uma excitação predeterminada na entrada do processo $u(t)$. Cabe ressaltar que a qualidade do modelo obtido está intimamente ligada às características do sinal de excitação. Na Figura 6, mostra-se como é obtido um modelo matemático a partir dos dados coletados de entrada e saída de um sistema. O modelo só reproduzirá as características do sistema que tiverem sido adequadamente excitados pelo sinal de entrada, sem sair das faixas de operação do sistema (AGUIRRE, 2015).

Figura 6: Coleta de dados para Identificação de Sistemas.

Uma questão de vital importância na identificação de sistemas é a escolha da estrutura. Conhecimentos *a priori* do sistema a ser identificado podem facilitar a escolha da estrutura. De acordo com o nível de conhecimento utilizado nesta escolha, os modelos são classificados como (LJUNG, 1999):

- Modelos caixa branca (*white box*);
- Modelos caixa cinza (*gray box*);
- Modelos caixa preta (*black box*).

Os modelos **caixa branca** têm sua estrutura totalmente definida a partir do conhecimento *a priori* do sistema a ser identificado. Neste caso, a forma da equação matemática que representa o sistema é previamente conhecida. Nos modelos **caixa cinza**, a utilização de conhecimento *a priori* simplifica os algoritmos de seleção de estrutura. Os modelos **caixa preta** não utilizam nenhuma informação conhecida *a priori* do sistema. A estrutura destes modelos é selecionada dentro de famílias conhecidas por apresentarem boa flexibilidade na modelagem de sistemas (LJUNG, 1999).

Na identificação *off-line*, os dados dos sinais de entrada e saída são armazenados e após isso, eles são processados para identificar o modelo. No caso da identificação *on-line*, o processo de coleta de dados e cálculo de parâmetros é executado continuamente, permitindo assim que se trabalhe com sistemas variantes no tempo. Neste caso, duas categorias de processamento de dados podem ser executados: em tempo real, em que eles são processados a cada intervalo de amostragem, e batelada, em que o conjunto de dados é processado depois de um certo número de medições ter sido feito.

A Identificação de Sistemas pode ser dividida em 5 etapas (LJUNG, 1999):

1. Projeto de experimentos;
2. Pré-processamento dos dados obtidos;
3. Escolha da melhor estrutura na representação do modelo;
4. Estimação de parâmetros;
5. Validação dos parâmetros do modelo obtido.

3.1 Definição dos parâmetros do experimento

O cenário e os parâmetros do experimento são importantes para garantir a qualidade da informação da dinâmica do sistema.

3.1.1 Sinais de excitação

Segundo (KURAMOTO, 2012), tem-se quatro métodos para construir sinais de excitação; por multinível, conceitos de otimização, álgebra abstrata usando autocorrelação e correlação cruzada específicas e finalmente o quarto método combina propriedades da álgebra e otimização.

Geralmente, se a cada intervalo de amostragem fosse aplicado à planta um novo valor de entrada, a excitação dificilmente seria adequada. Uma regra prática que normalmente funciona bem é, tendo-se definido o período de amostragem, manter constante cada valor escolhido aleatoriamente por um tempo, em torno de três a cinco intervalos de amostragem (AGUIRRE, 2015). Neste trabalho são considerados dois sinais:

- PRBS - *Sequência Binária Pseudo-Aleatória*;
- GMN - *Generalized Multiple Level*.

3.1.1.1 Sinal PRBS

O PRBS é um sinal de dois estados o qual pode ser gerado usando um registrador de deslocamento de realimentação, tal como é mostrado na Figura 7, onde n denota o número de registros ou de estados. Os registros são alimentados com valores digitais de zero ou um; e o vetor de estados é diferente de zero. Quando o relógio de pulsos é aplicado, o valor do estado k passa para o estado $(k + 1)$ e o primeiro estado é que determina a rota de realimentação. Os coeficientes de realimentação $a_1, \dots, a_n$ tomam o valor de 0 ou 1, assim o registrador de deslocamento gerará uma sequência de zeros e uns (AGUIRRE, 2015), (LARROTTA, 2015). Pode usar sinais PRBS para identificar modelos não lineares (RICHALET et al., 1978).

Figura 7: Sinal PRBS.

3.1.1.2 Sinal GMN

O sinal GMN (*Generalized Multiple-level Noise*) é uma generalização multinível do sinal GBN. Este sinal vai variando a amplitude aleatoriamente a cada intervalo de chaveamento determinado. A amplitude tem uma distribuição uniforme sobre uma faixa de valores do sinal, e tem valores discretos em cada intervalo de chaveamento (ZHU, 2001).

O período de chaveamento médio é denotado como T_{sw} e calculado como:

$$T_{sw} = \frac{T_{sa}}{3} \quad (3.1)$$

onde T_{sa} é 98% do tempo de acomodação.

3.1.2 Procedimento para o projeto de sinais de excitação

O procedimento para seleção de sinais de excitação é mostrado em (KURAMOTO, 2012). De onde foram tomados cinco passos para projetá-lo, e adicionou-se um passo para calcular a duração dele em cada patamar, então o procedimento define-se em seis itens:

1. Ter conhecimento *a priori* sobre o comportamento dinâmico da planta;
2. Calcular a amplitude do sinal de excitação;
3. Calcular as frequências máxima e mínima do sinal de excitação;
4. Estabelecer a duração mínima do experimento;
5. Estabelecer o período de amostragem adequado para identificar o sistema; e
6. Estabelecer a duração mínima do sinal de excitação em cada patamar.

3.1.2.1 Ter conhecimento *a priori* sobre o comportamento dinâmico da planta

Nesta parte são usados os pré-testes de identificação para ter um conhecimento inicial da dinâmica do sistema. Estes pré-testes consistem em excitar a planta com vários degraus, de tal forma que na saída não exceda a faixa de operação do sistema a ser identificado. Aqui tem que se definir os valores limites (máximo e mínimo) para as variáveis de entrada e saída. Assim também tem que se considerar os ganhos estáticos que são obtidos nos pré-testes. O sistema é excitado tanto em malha aberta como em malha fechada.

No caso da indústria, a informação *a priori* pode ser encontrada nos manuais de operação da planta, planos elétricos, lista de instrumentos, sinais digitais e analógicos, folha de dados dos equipamentos (sensores, transmissores, atuadores, bombas, motores, compressores e outros). Considerando uma aproximação da função de transferência de primeira ordem mais tempo morto, aqui pretende-se obter da planta o ganho estático, a constante de tempo e o tempo morto se tiver.

3.1.2.2 Calcular a amplitude do sinal de excitação

A amplitude do sinal de excitação tem que ter nível suficiente para excitar a dinâmica da planta dentro da faixa de valores que desejamos identificar, tanto em malha aberta como em malha fechada, ele não deve saturar a variável de saída do sistema.

Em malha aberta, o sinal de excitação é aplicado diretamente na entrada da planta, tomando-se cuidado de não escolher sinais de excitação que levem ao sistema a valores fora da faixa de operação. Em malha fechada, o sinal de excitação é aplicado no valor de referência (*setpoint*).

3.1.2.3 Calcular a frequência máxima e mínima do sinal de excitação

Com os resultados da informação *a priori*, calcula-se a constante de tempo maior e menor (τ_{min} e τ_{max}), e consequentemente define-se a frequência máxima e mínima (ω_L e ω_H) do sinal de excitação.

3.1.2.4 Estabelecer a duração mínima do experimento

De acordo com (ZHU, 2001) é recomendável considerar uma duração de experimento de 6 a 18 vezes o tempo de acomodação (que foi obtido para o sistema no pré-teste). De acordo com (VERHAEGEN; VERDULT, 2007) deveria ser de 10 vezes a maior constante de tempo do sistema a ser identificado, na Equação (3.2) define-se a faixa de valores que pode ser assumida para a duração do experimento, com base na proposta de (ZHU, 2001).

$$6 \cdot t_s \leq T_e \leq 18 \cdot t_s \quad (3.2)$$

sendo t_s o tempo de acomodação da malha e T_e a duração do experimento.

3.1.2.5 Cálculo do intervalo de amostragem

O intervalo de amostragem está ligado à natureza da dinâmica do processo ou sistema a ser identificado. Uma forma de identificar este parâmetro para definir um tempo correto para a coleta de dados é agir no sistema em malha aberta e ter uma aproximação do comportamento da dinâmica da planta, mas se o teste em malha aberta não for possível, resta fazer um teste em malha fechada e a partir dessa resposta obter o modelo da planta.

De acordo com (ZHU, 2001), o intervalo de amostragem recomendável para coletar dados de identificação devem seguir a seguinte relação:

$$T_{s,max} = \frac{t_s}{20} \quad (3.3)$$

$$T_{s,min} = \frac{t_s}{100} \quad (3.4)$$

onde $T_{s,max}$ é o intervalo máximo de amostragem, $T_{s,min}$ é o intervalo mínimo de amos-

tragem, t_s é o tempo de acomodação; para obter o tempo de acomodação o sistema pode ser excitado com um simples degrau na entrada em malha aberta ou também dos testes de identificação.

Segundo (SODERSTROM; STOICA, 1989), (RODRIGUEZ, 2015) o intervalo de amostragem deve ser:

$$T_s = \frac{t_s}{10} \quad (3.5)$$

3.1.2.6 Cálculo da duração mínima em cada patamar do sinal de excitação

Para o cálculo desse parâmetro segundo (AGUIRRE, 2015) considera-se de 3 a 5 vezes o intervalo de amostragem para o sinal de excitação PRBS. Na prática, observou-se que essa duração mínima para um valor constante de bit do sinal PRBS não conseguia excursionar a saída da variável controlada em toda a faixa de operação por conseguinte, a duração mínima do sinal de excitação foi multiplicada por dois, aumentando-se então a faixa de 3 a 10 vezes o intervalo de amostragem, essa relação mostra-se na Equação (3.6). Essa mesma regra foi aplicada no caso do sinal GMN como é mostrado na Equação (3.7).

$$3 * T_s \leq T_b \leq 10 * T_s \quad (3.6)$$

$$3 * T_s \leq T_{ch} \leq 10 * T_s \quad (3.7)$$

3.2 Normalização dos dados coletados

A normalização de dados é uma técnica de pré-processamento de dados que é utilizada na identificação de modelos para equiparar a importância das variáveis, pois coloca o valor dos dados coletados nas mesmas faixas de variação, não deixando, por exemplo, que variáveis que operem na faixa de 300 a 500 sejam processados junto com outras variáveis que operem na faixa de 0 a 5. Em (RODRIGUEZ, 2015) foram estudados seis tipos de normalização: por subtração da média, pelo valor máximo de cada variável, pelo desvio padrão, pelo valor máximo sem média e normalização em faixas iguais. Neste trabalho, destaca-se o uso das duas primeiras normalizações citadas. A normalização por subtração da média é definida na Equação (3.8) e a normalização pelo valor máximo de cada variável na Equação (3.10).

$$V_n(i) = X_n(i) - \mu \quad (3.8)$$

onde V_n é o vetor de dados normalizados, X_n é o vetor de dados originais e μ é a média aritmética de X_n , definida por:

$$\mu = \frac{\sum_{i=1}^N X_n(i)}{N} \quad (3.9)$$

$$V_n(i) = \frac{X_n(i)}{\max(X_n(i))} \quad (3.10)$$

3.3 Determinação da estrutura

O número de possíveis termos candidatos a fazer parte dos modelos não lineares pode facilmente crescer a milhares, segundo o grau de não linearidade e atrasos máximos (CHEN et al., 1990), sendo necessário a aplicação de algum procedimento de seleção, ele é denominado de determinação da estrutura.

Ao escolher a ordem do modelo, quando for menor que do sistema real, ele não terá a complexidade estrutural para representá-lo, agora quando for maior, terá repercussão na estimação de parâmetros. O problema para determinar a ordem de um sistema não linear é maior que um sistema linear (AGUIRRE, 2015).

Testes anteriores e simulações mostram que apenas poucos desses termos podem capturar a dinâmica, por exemplo, de processos SISO altamente não lineares (usualmente dez termos são suficientes). Os restantes podem ser desconsiderados com uma pequena deterioração na predição (KORENBERG et al., 1988), (CHEN et al., 1990).

3.3.1 Taxa de Redução de Erro - ERR

A Taxa de Redução de Erro ou ERR (*Error Reduction Ratio*) é uma das métricas que pode ser utilizada para a determinação dos regressores de um modelo não linear. O ERR de cada termo candidato é um número que indica a melhoria obtida na representação do sistema através da sua inclusão no modelo. Desta forma, é possível ordenar hierarquicamente os termos candidatos de acordo com a contribuição de cada um. O algoritmo ERR gera uma lista em ordem decrescente com os termos e suas contribuições na identificação do sistema (AGUIRRE, 2015).

O ERR é definido como o aporte na variância da variável dependente $\mathbf{Z}$, devido à inclusão de um novo termo na matriz de regressores auxiliares:

$$ERR_i = \frac{g_i \langle w_i, w_i \rangle}{\langle \mathbf{Z}, \mathbf{Z} \rangle} \quad (3.11)$$

sendo w_i os regressores do modelo não linear. Desta forma, termos não significativos (termos espúrios), podem ser removidos definindo um valor ERR, abaixo do qual aqueles termos não têm uma contribuição significativa no erro quadrático médio.

3.3.2 Critério de parada do crescimento da ordem do modelo

A taxa de redução do erro leva em consideração o desempenho do modelo (mediante a variância dos resíduos), mas não a complexidade do modelo (critério para a determinação do número de termos).

Os seguintes critérios consideram um compromisso entre o desempenho e a complexidade do modelo, sendo que os dois possuem um termo de variância dos resíduos (erro de predição) e um termo de ordem do modelo. O primeiro é uma medida de quão bem o modelo se ajusta aos dados e o segundo é uma medida da complexidade do modelo requerida para obter esse ajuste.

3.3.2.1 Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike (1974) é um dos critérios clássicos e mais usados na seleção de modelos dinâmicos (AKAIKE, 1974), (SEGHOUANE, 2009), (DRIDI; HADZAGIC, 2019). À medida que mais parâmetros são incluídos na ordem do modelo, o número de graus de liberdade aumenta, permitindo um ajuste mais exato aos dados. De acordo com (AKAIKE, 1974), o número ótimo de termos deve minimizar a seguinte função custo:

$$AIC(n_\theta) = N * \ln[\sigma_{erro}^2(n_\theta)] + 2n_\theta \quad (3.12)$$

sendo a variável N o comprimento do registro de dados, n_θ o número de parâmetros do modelo, σ^2 o erro médio quadrático, e o valor 2 da Equação (3.12) é o peso dado à inclusão de um termo no modelo. Segundo (LEONTARITIS; BILLINGS, 1987), este peso foi determinado através de um estudo realizado com a distribuição Chi-Square, a qual indica que a escolha deste peso é conveniente, proporcionando um intervalo de confiança de 0,05 (95%) na escolha dos termos corretos.

A função de custo de Akaike pode ser definida em duas parcelas, sendo que a primeira parcela da Equação (3.12) quantifica a diminuição da variância dos resíduos resultante da inclusão do novo termo e a segunda parcela representa o custo de inserir um novo termo no modelo. Portanto, se a redução em $\ln[\sigma_{erro}^2(n_\theta)]$ devida à inclusão do erro de um determinado termo, for maior que o custo de incluí-lo, $2n_\theta$, ele não deve ser inserido

no modelo (AGUIRRE, 2015).

3.3.2.2 Critério de Informação Bayesiano (BIC)

O Critério de Informação de Bayes é um critério de seleção da ordem do modelo proposto por Schwarz (1978). Assim como o Critério de Informação de Akaike (AIC), ele também leva em consideração o grau de parametrização do modelo e, da mesma forma, quanto menor o valor de BIC, mais adequada está a seleção das ordens dos modelos (SILVEIRA, 2010). A sua expressão é dada por:

$$BIC = N * \ln[\sigma_{erro}^2(n_\theta)] \ln(N) \quad (3.13)$$

3.4 Estimação de Parâmetros

Esta etapa tem a função de determinar valores adequados para os parâmetros que compõem o modelo, com base nas informações resultantes das etapas anteriores. Sendo assim, nessa fase ocorre a escolha e a utilização de algoritmos para realizar a estimação desses parâmetros. A maior parte dos algoritmos utilizados para esse fim é baseada no método clássico dos mínimos quadrados. A etapa de estimação de parâmetros resulta, então, na determinação dos valores numéricos dos parâmetros (AGUIRRE, 2015). Os modelos NARX polinomiais são estruturas lineares em seus parâmetros, portanto o problema de estimação de parâmetros pode ser resolvido mediante algum método baseado nos mínimos quadrados lineares.

A estimação de parâmetros é definida como a determinação experimental dos valores dos parâmetros que governam a dinâmica e o comportamento não linear de um processo, assumindo que a sua estrutura seja conhecida. Existe uma estreita relação entre o conhecimento do processo que é inicialmente disponível e o tipo de procedimento ótimo que pode ser utilizado para estimar os parâmetros (EYKHOFF, 1974). Podemos considerar os seguintes tipos de estimadores:

- Mínimos quadrados;
- Estimador de Markov;
- De máxima verossimilhança; e
- Estimador de Bayes.

Neste trabalho é utilizado o estimador de mínimos quadrados. O estimador de Markov precisa de um bom conhecimento da matriz de covariância do ruído. Para o estimador de verosimilhança é necessário o conhecimento da função de densidade de probabilidade do processo estocástico do qual os valores amostrados são tomados. No caso do estimador de Bayes o procedimento de risco mínimo e custo mínimo requer um conhecimento *a priori* da função de probabilidade dos parâmetros desconhecidos e do custo dos erros. Na Figura 8 mostra-se um diagrama de blocos sobre o funcionamento de estimadores de parâmetros.

Figura 8: Estimador de Parâmetros (EYKHOFF, 1974).

3.4.1 Método dos Mínimos Quadrados

O método dos mínimos quadrados, desenvolvido por Karl Gauss em 1795, para determinar as órbitas dos planetas, é um dos métodos mais conhecidos e utilizados nas diversas áreas de ciência e tecnologia para estimar parâmetros que acompanham os regressores escolhidos para representar um modelo não linear (AGUIRRE, 2015).

A técnica dos mínimos quadrados é uma ferramenta matemática para calcular os parâmetros de uma estrutura de termos que se supõe constituir o modelo de um sistema ou processo, que são selecionados de tal forma que a soma dos quadrados de seus erros seja minimizada (CHEN; BILLINGS; LUO, 1989), (FLAVOREA, 1997). Este método permite estimar o vetor de parâmetros $\hat{\theta}$ que caracteriza o modelo.

Supõe-se que o modelo matemático de um processo industrial seja dado pela expressão:

$$y(t) = x_1(t)\theta_1 + x_2(t)\theta_2 + \dots + x_n(t)\theta_n \quad (3.14)$$

onde $y(t)$ é a variável de saída do sistema a ser identificada, $[x_1(t), x_2(t), \dots, x_n(t)]$ é o conjunto de funções que dependem do tempo que representam os componentes do modelo,

$\theta_1, \theta_2, \dots, \theta_n$ são o conjunto de parâmetros constantes que acompanham cada componente do modelo.

A representação matricial da função (3.14) pode-se expressar como:

$$y = \Phi\theta \quad (3.15)$$

$$y = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix}, \Phi = \begin{bmatrix} x_1(1) & x_2(1) & \dots & x_n(1) \\ x_1(2) & x_2(2) & \dots & x_n(2) \\ \dots & \dots & \ddots & \dots \\ x_1(N) & x_2(N) & \dots & x_n(N) \end{bmatrix}, \theta = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix} \quad (3.16)$$

onde N é o número de observações realizadas (tamanho do vetor de entrada dos dados), n é o número de termos do qual está constituído o modelo matemático.

3.5 Validação do modelo

Uma vez que o processo foi identificado, testes de validação do modelo devem ser aplicados para detectar se existem termos não modelados nos resíduos, pois a ausência de algum termo importante no modelo pode provocar a polarização dos parâmetros ou outros problemas, como dinâmicas não modeladas. Os testes de validação do modelo envolvem vários procedimentos, verificando como o modelo se relaciona com os dados observados, visando a sua aplicação futura (LJUNG, 1999).

Uma forma de comparar dois modelos diferentes obtidos com duas estruturas de modelo diferentes é avaliar seu desempenho quando aplicado a um conjunto de dados para o qual nenhum deles foi ajustado. Seleciona-se então o modelo que mostre o melhor desempenho. Tal procedimento é conhecido como validação cruzada (Ljung, 1999). Sua desvantagem é a necessidade de manter um conjunto de dados coletados para as comparações, de forma que não se pode usar todas as informações disponíveis para estimar os modelos.

A obtenção de modelos pode auxiliar no projeto de controladores que estabilizem um dado processo e que também executem um critério de otimização. A identificação de sistemas é muito útil quando a modelagem do processo (através de leis físicas) é difícil ou quando se necessita de modelos que sejam constantemente atualizados (identificação *on-line*).

Uma vez realizada a etapa de identificação, realizá-se a validação do modelo, ela consiste em comparar e avaliar se o modelo identificado representa o comportamento

dinâmico do processo. Considerando-se se os dados coletados são utilizados para estimar ou validar o modelo, pode-se diferenciar dois tipos de validação:

- Autovalidação
- Validação cruzada

Na Autovalidação de um modelo, os dados coletados são utilizados para estimar um modelo e o mesmo conjunto de dados é utilizado para validá-lo. A validação cruzada é mais recomendável para verificar se um modelo representa o processo ou sistema a identificar. Nesta validação, para identificar o modelo são utilizados determinados dados e para validar o modelo são utilizados outros dados. A primeira opção para realizar a validação cruzada é coletar dados de uma só vez e a partir daí separar os dados, em dados de estimação e dados de validação. E a segunda opção é coletar dados em separado para estimar e validar, os dados de validação podem estar em uma faixa de amplitude menor do que na faixa de estimação.

Um critério para avaliar vários modelos considerando os ordens da estrutura do modelo é utilizando o índice de desempenho FPE (*Final Prediction Error*), que leva em conta o número de parâmetros e a função perda. Quanto menor o índice FPE, melhor será o modelo. O cálculo do índice FPE é realizado através da Equação (3.17).

$$FPE = \frac{(N + n_\theta)}{N - n_\theta} V_N(\theta) \quad (3.17)$$

sendo n_θ é o número total de parâmetros estimados, N é a quantidade de pontos coletados e $V_N(\theta)$ é a função perda, que é o somatório normalizado do erro quadrático.

3.5.1 Validação estatística

Este procedimento verifica se os resíduos $\xi(t)$ do modelo não linear são brancos e não correlacionados com a entrada, mediante funções de auto-correlação dos resíduos e a correlação cruzada dos resíduos com a entrada. Para fazer isso é preciso avaliar se existem correlações estatisticamente significativas nos resíduos.

3.5.2 Validação dinâmica

A validação dinâmica verifica se o modelo reproduz as características dinâmicas do sistema identificado. Na prática, consiste em aplicar novos dados de entrada ao modelo obtido e comparar as saídas simuladas obtidas com os dados de saída reais.

3.5.3 Análise de Resíduos

A diferença da saída do modelo com os dados reais da planta corresponde aos erros de identificação. Não é possível afirmar que esses erros de identificação ocorreram devido a problemas na estimação de parâmetros. A análise de resíduos indica se os parâmetros do modelo foram ou não estimados corretamente (AGUIRRE, 2015). O vetor de resíduos $\varepsilon(t)$ é definido com sendo a diferença entre o vetor de dados observados e de predições um passo à frente do modelo:

$$\varepsilon(t) = y(t) - \hat{y}(t/t - 1, \hat{\theta}_N) \quad (3.18)$$

Pode-se calcular índices de qualidade a partir dos resíduos, conforme indicado a seguir (LJUNG, 1999):

$$S_1 = \max |\varepsilon(t)| \quad (3.19)$$

$$S_2 = \sqrt{\frac{1}{N} \sum_{t=1}^N \varepsilon(t)^2} \quad (3.20)$$

4 ESTRUTURAS NÃO LINEARES

Neste capítulo são tratadas duas estruturas não lineares; neste caso o modelo NARX polinomial e o modelo de Hammerstein-Wiener baseado em blocos orientados, correspondendo à combinação dos modelos de Hammerstein e de Wiener.

4.1 Modelo NARX

O modelo NARX (*Nonlinear Auto-Regressive with eXogenous Inputs*) abrange uma classe importante de sistemas não lineares de tempo discreto, que expressa o valor da saída $y(t)$ em função dos valores prévios dos sinais de entrada-saída do processo como mostra a Equação (4.1) (PRÖLL; KARIM, 1994), (JERÔNIMO, 1998), (BILLINGS, 2013), (WESTWICK et al., 2018), (WORDEN et al., 2018) .

$$y(t) = F^l[y(t-1), y(t-2), \dots, y(t-n_y), u(t), u(t-1), u(t-2), \dots, u(t-n_u)] + e(t) \quad (4.1)$$

sendo $y(t)$ a saída do modelo, F^l a função não linear do modelo com grau de não linearidade $l \in N$, sendo n_y e n_u os maiores atrasos na saída $y(t)$ e na entrada $u(t)$, e $e(t)$ o ruído do sistema, respectivamente. A forma da função não linear F^l normalmente não é conhecida *a priori*. Assim, a dinâmica do sistema pode ser reconstruída utilizando uma aproximação polinomial, em que l é o grau máximo do polinômio utilizado para representar F^l . O diagrama de blocos do modelo NARX é mostrado na Figura 9.

É possível perceber que, com o aumento do grau de não linearidade do modelo, ocorre o fenômeno da explosão combinatória no número de parâmetros. Para contornar esse problema, são utilizados métodos como a taxa de redução de erro (ERR), que visam selecionar exclusivamente os parâmetros mais significativos do modelo.

Neste trabalho, com a aplicação do método do ERR foram considerados 83 regressores entre lineares e não lineares para identificar os modelos NARX, com um grau máximo 3 de não linearidade, 3 atrasos de intervalo de amostragem na entrada e saída. Esses regressores são mostrados na Tabela 3 e são a combinação sem repetição dos atrasos na entrada e saída

Figura 9: Diagrama de blocos para o Modelo NARX.

dos dados coletados $(u(k-1), u(k-2), u(k-3), y(k-1), y(k-2), y(k-3))$, primeiro em combinação de potência de grau 2 e posteriormente de grau 3. Por exemplo, para formar as combinações de grau 2 com o regressor $y(k-1)$, a sequência dos regressores gerados seria $y(k-1)^2$, $y(k-1) * y(k-2)$, $y(k-1) * y(k-3)$, $y(k-1) * u(k-1)$, $y(k-1) * u(k-2)$, $y(k-1) * u(k-3)$; na seguinte sequência a quantidade de regressores seria menos um e assim sucessivamente até chegar ao último regressor $u(k-3)$. Para gerar os regressores de grau 3 o procedimento é similar ao de grau 2.

Na Figura 10 mostra-se o algoritmo usado neste trabalho para identificar o modelo NARX (AGUIRRE, 2015), o qual funciona basicamente da seguinte forma:

- Carregar os dados de identificação;
- Verificar se precisa de reamostragem, testando o modelo com dados variando o período de amostragem até obter um modelo com melhor *fit*;
- Definir os dados de entrada e saída para cada sistema a identificar;
- Definir os regressores da função NARX;
- Criar a matriz Ψ com os regressores definidos;
- Executar a função NARX;
- Calcular o ERR e obter o modelo NARX.

Tabela 3: Regressores considerados para os modelos NARX.

Item	Regressores de 1 a 30	Regressores de 31 a 60	Regressores de 61 a 83
1	$u(k-1)$	$y(k-1)^2 u(k-1)$	$y(k-2)u(k-2)^2$
2	$u(k-2)$	$y(k-1)^2 u(k-2)$	$y(k-2)u(k-2)u(k-3)$
3	$u(k-3)$	$y(k-1)^2 u(k-3)$	$y(k-2)u(k-3)^2$
4	$y(k-1)$	$y(k-2)^2 y(k-1)$	$y(k-3)^3$
5	$y(k-2)$	$y(k-1)y(k-2)y(k-3)$	$y(k-3)^2 u(k-1)$
6	$y(k-3)$	$y(k-1)y(k-2)u(k-1)$	$y(k-3)^2 u(k-2)$
7	$y(k-1)^2$	$y(k-1)y(k-2)u(k-2)$	$y(k-3)^2 u(k-3)$
8	$y(k-1)y(k-2)$	$y(k-1)y(k-2)u(k-3)$	$y(k-3)u(k-1)^2$
9	$y(k-1)y(k-3)$	$y(k-1)^2 y(k-2)$	$y(k-3)u(k-1)u(k-2)$
10	$y(k-1)u(k-1)$	$y(k-1)y(k-3)u(k-1)$	$y(k-3)u(k-1)u(k-3)$
11	$y(k-1)u(k-2)$	$y(k-1)y(k-3)u(k-2)$	$y(k-3)u(k-2)u(k-3)$
12	$y(k-1)u(k-3)$	$y(k-1)y(k-3)u(k-3)$	$y(k-3)u(k-2)^2$
13	$y(k-2)^2$	$y(k-1)y(k-1)^2$	$y(k-3)u(k-3)^2$
14	$y(k-2)y(k-3)$	$y(k-1)u(k-1)u(k-2)$	$u(k-1)^3$
15	$y(k-2)u(k-1)$	$y(k-1)u(k-1)u(k-3)$	$u(k-1)^2 u(k-2)$
16	$y(k-2)u(k-2)$	$y(k-1)u(k-2)^2$	$u(k-1)^2 u(k-3)$
17	$y(k-2)u(k-3)$	$y(k-1)u(k-2)u(k-3)$	$u(k-1)u(k-2)^2$
18	$y(k-3)^2$	$y(k-1)u(k-3)^2$	$u(k-1)u(k-2)u(k-3)$
19	$y(k-3)u(k-1)$	$y(k-2)^3$	$u(k-1)u(k-3)^2$
20	$y(k-3)u(k-2)$	$y(k-2)^2 y(k-3)$	$u(k-2)^3$
21	$y(k-3)u(k-3)$	$y(k-2)^2 u(k-1)$	$u(k-2)^2 u(k-3)$
22	$u(k-1)^2$	$y(k-2)^2 u(k-2)$	$u(k-2)u(k-3)^2$
23	$u(k-1)u(k-2)$	$y(k-2)^2 u(k-3)$	$u(k-3)^3$
24	$u(k-1)u(k-3)$	$y(k-2)y(k-3)^2$	
25	$u(k-2)^2$	$y(k-2)y(k-3)u(k-1)$	
26	$u(k-2)u(k-3)$	$y(k-2)y(k-3)u(k-2)$	
27	$u(k-3)^2$	$y(k-2)y(k-3)u(k-3)$	
28	$y(k-1)^3$	$y(k-2)u(k-1)^2$	
29	$y(k-1)^2 y(k-2)$	$y(k-2)u(k-1)u(k-2)$	
30	$y(k-1)^2 y(k-3)$	$y(k-2)u(k-1)u(k-3)$	

Fonte: Autor

Figura 10: Fluxograma para obter o modelo NARX.

4.2 Modelo de Hammerstein

O modelo de Hammerstein é um dos tipos de modelos com blocos orientados que resulta da união de um bloco linear dinâmico mais um bloco não linear estático (NARENDRA; GALLMAN, 1966), (ZHU, 2001). Apesar deste modelo ser muito simples, ele pode representar diversos processos industriais.

As vantagens desses modelos não lineares são:

1. Baixo custo para os testes de identificação;
2. Baixo custo na carga de sistema computacional requerido; e
3. Fácil de compreender.

O modelo de Hammerstein é considerado como um dos modelos não lineares mais fáceis de ser usado na identificação para representar processos industriais com atuadores não lineares e com ganhos variáveis (ZHU, 2001), quando comparado com outras estruturas não lineares. A iteração para determinar os parâmetros do bloco linear e do bloco não linear pode ser realizada separadamente. Aqui as técnicas lineares podem ser utilizadas para estimar parâmetros do modelo. O diagrama de blocos do modelo de Hammerstein é mostrado na Figura 11, onde $u(k)$ representa a entrada do sistema, $y(k)$ representa a saída do sistema, $x(k)$ representa a saída da parte não linear, $f(u)$ é a função não linear, $G(z)$ é a função de transferência da parte linear do modelo e $v(t)$ é a perturbação na saída do processo.

Figura 11: Modelo de Hammerstein.

As equações para definir cada uma das componentes do modelo de Hammerstein são:

$$f[u(k)] = \beta_1 u(k) + \beta_2 u^2(k) + \dots + \beta_m u^m(k) \quad (4.2)$$

$$G(z) = \frac{B(z)}{A(z)} = \frac{b_0 + b_1 z^{-1} + \dots b_n z^{-l}}{1 + a_1 z^{-1} + \dots a_n z^{-l}} \quad (4.3)$$

$$Y(z) = G(z)X(z) + V(z) \quad (4.4)$$

$$Y(z) = \frac{b_0 + b_1 z^{-1} + \dots b_n z^{-l}}{1 + a_1 z^{-1} + \dots a_n z^{-l}} X(z) + V(z) \quad (4.5)$$

$$y(k) = z^{-1}Y(z) \quad (4.6)$$

4.3 Modelo de Wiener

O modelo de Wiener consta de um bloco linear seguido de um bloco não linear. O primeiro representa a dinâmica da planta, que se assume como a componente linear e o bloco seguinte corresponde ao comportamento não linear, que caracteriza as condições estáticas (ZHU, 2001).

Na Figura 12 apresentam-se estes dois blocos, sendo $u(k)$ e $y(k)$ a entrada e saída do modelo de Wiener, respectivamente. A parte linear representa a tradicional função de transferência de um sistema linear, a qual pode ser representada no domínio do tempo discreto por:

$$R(z) = \frac{B(z)}{A(z)}U(z) \quad (4.7)$$

A variável intermediária $d(t)$ pode ser expressa como:

$$D(z) = R(z) + V(z) = \frac{B(z)}{A(z)}U(z) + V(z) \quad (4.8)$$

O modelo de Wiener inclui um ruído branco gaussiano estocástico $v(k)$ com média zero e variância σ^2 . Usando a transformada Z inversa de $D(z)$, obtém-se $d(k)$ no domínio do tempo por:

$$d(k) = Z^{-1}D(z) \quad (4.9)$$

Com a variável $d(k)$ no domínio temporal obtém-se a saída $y(k)$ através da função não linear f :

$$y(k) = f[d(k)] \quad (4.10)$$

4.4 Modelo de Hammerstein-Wiener

O modelo de Hammerstein-Wiener compreende três blocos (FALKNER, 1988), (ZHU, 2001), (LI et al., 2011), (WILLS et al., 2013), (LI; JIA, 2019):

Figura 12: Modelo de Wiener.

- Um bloco com um modelo não linear estático;
- Um bloco com um modelo de um sistema dinâmico linear;
- Um bloco com um modelo não linear estático.

Os blocos não lineares são usados para capturar as não linearidades estáticas do sistema, enquanto que o bloco linear captura o resto da dinâmica do sistema (ZHU, 2001). O modelo de Hammerstein-Wiener pode ser utilizado como uma estrutura de modelo caixa-preta, porque proporciona uma parametrização flexível para modelos não lineares. Igualmente, este modelo pode ser utilizado como estrutura caixa-cinza para capturar o conhecimento físico acerca das características do processo.

Figura 13: Modelo de Hammerstein-Wiener.

Na Figura 13 observa-se o modelo de Hammerstein-Wiener na forma monovariável. Assume-se que:

- As funções não lineares $f_1(u)$ e $f_2(w)$ sejam contínuas.
- A função de saída $f_2(w)$ não linear é monotônica e invertível.
- A saída da parte linear $w_2(k)$ é perturbada com um sinal estocástico estacionário $v(k)$ com média zero.
- O sinal $v(k)$ é o ruído de medição.

- O sinal $w_1(k)$ é a saída do bloco não linear $f_1(u)$.

Com as considerações anteriores definem-se as equações para o modelo de Hammerstein-Wiener (HW) dadas por:

$$w_1(k) = f_1[u(k)] \quad (4.11)$$

$$w(k) = w_2(k) + v(k) = G(q)w_1(k) + v(k) \quad (4.12)$$

$$y(k) = f_2[w(k)] = f_2[G(q)f_1[u(k)] + v(k)] \quad (4.13)$$

Pode-se mencionar alguns trabalhos onde foram aplicados os modelos de Hammerstein-Wiener (WANG; DING, 2012), (ZMARZLY; FRACZ, 2016), (ESMAEILANI; GHAI-SARI; BAGHERZADEH, 2019), (PêS et al., 2019).

Neste trabalho, para representar o modelo HW, consideram-se cinco tipos de estruturas não lineares como os blocos de entrada e saída: *pwnlinear*, *sigmoidnet*, *saturation*, *deadzone* e *wavenet*. Combinando essas cinco estruturas resultam em 25 possibilidades de combinações e elas são mostrados na Tabela 4. Para encontrar o melhor modelo HW considerando as 25 possíveis combinações, o modelo que tem o maior índice *fit* é selecionado. Os parâmetros das funções não lineares foram deixadas em valores por *default* no momento de calcular os modelos, o que foi-se alterando para melhorar o desempenho do *fit* foi o período de amostragem.

O bloco linear tem a estrutura *Output Error* (OE) segundo a Equação 4.14.

$$y(k) = \frac{B(q)}{F(q)}u(k - nk) + e(k) \quad (4.14)$$

onde nb é a ordem do polinômio B, nf a ordem do polinômio F e nk é o atraso na entrada, os parâmetros nb , nf e nk são testados segundo a Tabela 5, eles representam 24 combinações para cada ordem de nb , dando em total de 144 modelos lineares a ser testados. Ao realizar o algoritmo recursivo não foi considerado para o bloco linear funções impróprias (funções de transferência onde o grau do numerador é menor que o grau do denominador).

Para escolher o modelo de Hammerstein-Wiener se realizaram várias iterações até encontrar o modelo com melhor índice *fit*, as iterações resultam das combinações do cinco

Tabela 4: Estruturas nos blocos de entrada e saída dos modelos HW.

	Estrutura na Entrada	Estrutura na Saída
1	pwlinear	pwlinear
2	pwlinear	sigmoidnet
3	pwlinear	saturation
4	pwlinear	deadzone
5	pwlinear	wavenet
6	sigmoidnet	pwlinear
7	sigmoidnet	sigmoidnet
8	sigmoidnet	saturation
9	sigmoidnet	deadzone
10	sigmoidnet	wavenet
11	saturation	pwlinear
12	saturation	sigmoidnet
13	saturation	saturation
14	saturation	deadzone
15	saturation	wavenet
16	deadzone	pwlinear
17	deadzone	sigmoidnet
18	deadzone	saturation
19	deadzone	deadzone
20	deadzone	wavenet
21	wavenet	pwlinear
22	wavenet	sigmoidnet
23	wavenet	saturation
24	wavenet	deadzone
25	wavenet	wavenet

Fonte: Autor

Tabela 5: Valores considerados para os graus de nb , nf e nk nos modelos HW.

Coefficientes	Valores considerados
nb	de 1 a 6
nf	de 1 a 8
nk	de 1 a 3

Fonte: Autor

tipos de blocos não-lineares (pwlinear, sigmoidnet, saturação, *deadzone* e wavenet) e a combinação das ordens para o bloco linear.

O algoritmo para obter o modelo HW funciona basicamente da seguinte forma:

- Carregar os dados de identificação e validação e definir os dados de entrada e saída;
- Indicar os ordens para o bloco linear;

- Testar as 25 combinações possíveis para os blocos não lineares na entrada e saída do modelo;
- Verificar se terminou a iteração, senão continuar testando outro modelo;
- Escolher o modelo com melhor *fit* e realizar a validação cruzada desse modelo.

Figura 14: Fluxograma para obter o modelo HW.

4.4.1 Função *pwlinear*

A função *pwlinear* é representada por:

$$y = F_{pw}(x, \theta) \quad (4.15)$$

onde y e x são escalares, θ representa os números de ponto de ruptura e o valor de não linearidade desses pontos. Na Figura 15 observa-se que a parte direita e que a parte esquerda da função são constantes, e na parte central, ela é composta por duas funções lineares com tangentes diferentes.

Figura 15: Função *pwlinear*.

4.4.2 Função *Sigmoidnet*

A função *sigmoidnet* é definida como:

$$y = F_{sig}(x) \quad (4.16)$$

onde y é um escalar e x é um vetor linha com dimensão m . A função de rede sigmoide é baseada na seguinte expressão:

$$F(x) = (x - r)PL + a_1(f(x - r)Qb_1 + c_1) + \dots + a_n(f(x - r)Qb_n + c_n) + d \quad (4.17)$$

onde f é uma função sigmoide dada pela seguinte equação:

$$f(a) = \frac{1}{e^{-a} + 1} \quad (4.18)$$

P e Q são matrizes de dimensão $m * p$ e $m * q$, respectivamente.

4.4.3 Função Saturação

A função Saturação é representada por:

$$y = F_{sat}(x, \theta) \quad (4.19)$$

onde y e x são escalares, θ representa os parâmetros a e b que definem o intervalo linear $[a, b]$. Na Figura 16 observa-se que as partes à direita e à esquerda da função são constantes, e na parte central ela é composta por uma função linear.

Figura 16: Função saturação.

4.4.4 Função *Deadzone*

A função *Deadzone* é definida como:

$$y = F_{dz}(x, \theta) \quad (4.20)$$

onde x e y são valores escalares e θ representa os parâmetros a e b , o qual define o intervalo $[a, b]$ onde a saída tem valor zero. Na Figura 17 mostra-se a forma dessa função. A função não linear *deadzone* tem as seguintes características:

$$\begin{aligned} a \leq x < b & \quad F_{dz}(x) = 0 \\ x < a & \quad F_{dz}(x) = x - a \\ x \geq b & \quad F_{dz}(x) = x - b \end{aligned} \quad (4.21)$$

Figura 17: Função *Deadzone*.

4.4.5 Função *Wavenet*

A função *Wavenet* é definida como:

$$y = F_{wn}(x, \theta) \quad (4.22)$$

onde y é escalar, x é um vetor de regressores de dimensão m e θ representa os parâmetros na expansão de *Wavenet*. A função *wavenet* é baseada na seguinte expansão:

$$\begin{aligned} F_{wn}(x, \theta) = & (x - r)PL + a_{s_1}f[b_{s_1}((x - r)Q - c_{s_1})] + \dots \\ & + a_{s_ns}f[b_{s_ns}((x - r)Q - c_{s_ns})] \\ & + a_{w_1}g[b_{w_1}((x - r)Q - c_{w_1})] + \dots \\ & + a_{w_nw}g[b_{w_nw}((x - r)Q - c_{w_nw})] + d \end{aligned} \quad (4.23)$$

$$f(z) = e^{-0.5zz^T}$$

$$g(z) = (m - zz^T)e^{-0.5zz^T}$$

onde,

- $f(z)$ é a função radial chamada de função escalada e z é a entrada dessa função.
- $g(z)$ é a função radial chamada de função wavenet e z é a entrada dessa função.
- θ representa os parâmetros do estimador não linear.
- P e Q são as matrizes de projeção de ordem $m \times p$ e $m \times q$, respectivamente.
- r é o valor médio do vetor regressor calculado a partir do dado estimado.
- a_s, b_s, a_w e b_w são os parâmetros de escala e de wavenet. Parâmetros com o subíndice

s são os parâmetros de escala e os parâmetros com o subíndice w são os parâmetros de *wavenet*.

- L é definido como um vetor de dimensão $p \times 1$.
- a_s e b_s são definidos como vetores de dimensão $1 \times q$
- d é a saída de *offset*, especificada como um escalar.

5 EXPERIMENTOS E RESULTADOS

Neste capítulo apresentam-se os experimentos que foram feitos para identificar os modelos não lineares de três variáveis controladas da Planta Piloto de Neutralização de pH no Laboratório de Controle de Processos Industriais da EPUSP. Na Figura 5 foi mostrada a arquitetura de rede de como os elementos do sistema digital de controle automático estão se comunicando. Os sinais de medição e de controle são escritos e lidos através de uma ferramenta de conexão com o servidor OPC do sistema 800xA. Essas variáveis são armazenadas no Workspace do Matlab.

As três variáveis controladas a terem seus modelos não lineares identificados são:

- Temperatura;
- Nível;
- pH.

Estas variáveis foram identificadas independentemente e isoladamente no caso SISO. Cada variável de controle foi excitada através da variável manipulada em malha aberta ou do *setpoint* da variável controlada em malha fechada, medindo essa saída sem interessar o que está acontecendo com as demais saídas, supondo que elas tenham influência praticamente nula na dinâmica das outras duas malhas.

A parte experimental desta pesquisa está dividida nas seguintes etapas:

- Pré-testes de cada uma das três variáveis;
- Experimentos de identificação não linear;
- Validação dos modelos obtidos.

5.1 Pré-testes de Identificação

Os pré-testes de identificação são usados para se ter uma primeira aproximação do modelo de um sistema e eles dão uma ideia do seu comportamento dinâmico. O sinal usado para excitar o processo é o degrau, considerando que o sistema esteja no ponto de equilíbrio no qual se pretende identificar o modelo. Os dados coletados na entrada e saída do processo são usados para identificar um modelo linear, neste caso o modelo linear é uma função de transferência de primeira ordem mais tempo morto, de acordo com a Equação (5.1), com isto é identificado o ganho K , a constante de tempo τ e o atraso do sistema θ .

$$G(s) = \frac{K \cdot e^{-\theta \cdot s}}{\tau \cdot s + 1} \quad (5.1)$$

Nesta seção, obtém-se a primeira aproximação da dinâmica das três malhas de controle. Os testes de resposta ao degrau aqui realizados visam auxiliar na obtenção dos seguintes parâmetros do processo:

- Intervalo de amostragem para o teste de identificação não linear;
- Tempo de coleta de dados de identificação do modelo não linear;
- Faixa de operação dos valores de entrada da planta;
- Calcular os parâmetros do sinal de excitação PRBS e GMN.

Tabela 6: Faixa de operação das três variáveis a serem identificadas.

Temperatura	Nível	pH
De 22°C a 45°C	De 30% a 80%	De 3 a 11

5.1.1 Pré-teste de Identificação da Malha de Temperatura

A malha de controle de temperatura pode trabalhar em uma faixa de operação nominal de temperatura que varia desde 22°C até 45°C. No momento de realizar os pré-testes foi considerado que a variação da temperatura ambiente vai influenciar na resposta da curva de reação do processo de temperatura.

5.1.1.1 Pré-teste de Identificação da malha aberta de Temperatura

O pré-teste de identificação da malha aberta de temperatura consiste na excitação da entrada da planta com um sinal degrau $u(t)$ e medindo na saída a variável do processo $y(t)$. As variações de temperatura ocorrem de duas formas: para aquecer a mistura no tanque de reação TR é necessário alimentar com tensão uma resistência elétrica de 5 kW e para resfriar é preciso desligar a resistência elétrica e injetar água à temperatura ambiente no TR. A variável manipulada que controla a temperatura está dividida na faixa de 50% a 100% quando se deseja acionar a resistência elétrica e de 0% a 50% quando se deseja abrir a entrada de água de resfriamento. Quando a variável manipulada está em 50%, a resistência elétrica está desligada e a vazão de água de resfriamento é nula. Neste caso, supõe-se que a temperatura nominal de operação do TR é a temperatura ambiente. Ressalta-se que tanto o acionamento da resistência elétrica quanto da injeção de água fria é feito por meio de sinais do tipo Pulse Width Modulation - PWM, o que permite modular o sinal sendo aplicado. Na Figura 18 mostra-se o diagrama de blocos da malha aberta de temperatura. Para cada degrau foram calculadas as funções de transferência com o comando "procest" do Matlab 2017 a partir dos dados coletados de entrada e saída e são mostradas na Tabela 7.

Figura 18: Diagrama de blocos da malha aberta de Temperatura.

Os degraus que foram aplicados na variável manipulada em malha aberta são:

- Degrau positivo de 50,0% para 52,0%;
- Degrau positivo de 50,0% para 54,0%;
- Degrau positivo de 50,0% para 56,0%;
- Degrau positivo de 50,0% para 66,0%;
- Degrau negativo de 50,0% para 40,0%;
- Degrau negativo de 58,0% para 0,0%;
- Degrau negativo de 62,0% para 0,0%.

Esses degraus aplicados na entrada da planta começam em 50,0%, quer dizer que foi considerado que o sistema parte da temperatura ambiente antes de dar o degrau de excitação na planta. Nas Figuras 19a, 19b, 19c, 19d, 20a, 20b e 20c observam-se as curvas de reação para cada degrau de excitação.

(a) De 50,0% para 52,0%

(b) De 50,0% para 54,0%

(c) De 50,0% para 56,0%

(d) De 50,0% para 66,0%

Figura 19: Degraus positivos na variável manipulada na malha aberta de Temperatura.

(a) De 50,0% para 40,0%

(b) De 58,0% para 0,0%

(c) De 62,0% para 0,0%

Figura 20: Degraus negativos na variável manipulada na malha aberta de Temperatura.

Tabela 7: Funções de transferência da Temperatura, obtidas do pré-teste de identificação em malha aberta.

	Degrau	Função de Transferência	fit
Malha Aberta (Degrau na entrada)	De 50 para 52	$G_{MA_50_52}(s) = \frac{1,6626e^{-91,82 \cdot s}}{2586,2 \cdot s + 1}$	95,04 %
	De 50 para 54	$G_{MA_50_54}(s) = \frac{1,2818e^{-73,17 \cdot s}}{2642,6 \cdot s + 1}$	98,68 %
	De 50 para 56	$G_{MA_50_56}(s) = \frac{1,6384e^{-31,77 \cdot s}}{2714 \cdot s + 1}$	97,43 %
	De 50 para 66	$G_{MA_50_66}(s) = \frac{1,6435e^{-70,90 \cdot s}}{2980,7 \cdot s + 1}$	97,43 %
	De 50 para 40	$G_{MA_50_40}(s) = \frac{0,2708e^{-44,37 \cdot s}}{1263,3 \cdot s + 1}$	96,91 %
	De 58 para 0	$G_{MA_58_0}(s) = \frac{0,1880e^{-2,0 \cdot s}}{1280,4 \cdot s + 1}$	87,27 %
	De 62 para 0	$G_{MA_62_0}(s) = \frac{0,2826e^{-54,9 \cdot s}}{1320,4 \cdot s + 1}$	93,61 %

5.1.1.2 Pré-teste de Identificação da malha fechada de Temperatura

Para realizar o pré-teste de identificação da malha fechada de temperatura, o *setpoint* do processo é excitado com um sinal degrau partindo do ponto de operação, que é a temperatura ambiente. Neste caso, e a variável manipulada vale 50 %. Os parâmetros do controlador PI considerados são mostrados na Tabela 8. Na Figura 21 mostra-se o diagrama de blocos da malha fechada de temperatura. As funções de transferência obtidas do pré-teste de identificação em malha fechada para a planta de temperatura são mostradas na Tabela 9.

Tabela 8: Parâmetros do controlador PI da malha fechada de Temperatura.

Controlador PI da Temperatura	K_p	T_i
<i>Heating</i>	15	126
<i>Cooling</i>	20	10

Figura 21: Diagrama de blocos da malha fechada de Temperatura.

Tabela 9: Funções de transferência da Temperatura, obtidas do pré-teste de identificação em malha fechada.

	Degrau	Função de Transferência	fit
Malha Fechada (Degrau no SP)	De 24 para 27	$G_{MF_24_28}(s) = \frac{1,6434e^{-40,00 \cdot s}}{3623,1 \cdot s + 1}$	92,28 %
	De 24 para 35	$G_{MF_24_35}(s) = \frac{0,9178e^{-58,21 \cdot s}}{1977,8 \cdot s + 1}$	98,65 %
	De 25 para 40	$G_{MF_25_40}(s) = \frac{1,5336e^{-40,00 \cdot s}}{3223,2 \cdot s + 1}$	97,64 %

(a) De 24 °C para 27 °C

(b) De 24 °C para 35 °C

(c) De 24 °C para 40 °C

Figura 22: Degraus positivos no SP da malha de Temperatura.

5.1.2 Pré-teste de Identificação da Malha de Nível

Para realizar o pré-teste de identificação na malha de nível, a variável manipulada é a porcentagem de abertura da válvula de controle e a variável controlada é a altura do fluido no tanque reator. A variável manipulada atua sobre uma válvula de controle através de um sinal elétrico de 4 a 20 mA para regular a porcentagem de abertura e o nível é medido por um transmissor de nível de pressão diferencial.

5.1.2.1 Pré-teste de Identificação da malha aberta de Nível

No momento de fazer o pré-teste de identificação da malha aberta de nível para obter as curvas de reação, observa-se que a variável controlada responde muito lentamente para se estabilizar, tem que se ajustar com muita precisão e esperar o tempo necessário para ver que o nível está estável. Na Figura 23 mostram-se as variáveis manipulada e controlada. O ponto de nominal de operação da malha de nível é 75,0% da altura máxima do tanque de reação. Os valores que foram testados na malha aberta foram escolhidos de acordo com a faixa de operação da malha de nível. Na Figura 24 mostra-se as respostas ao degrau da malha aberta de temperatura. Os modelos obtidos a partir das respostas mostradas na Figura 24 são apresentados na Tabela 10.

Figura 23: Diagrama de blocos da malha aberta de Nível.

Como no caso da malha de temperatura, o primeiro teste é para fazer uma aproximação da função de transferência de primeira ordem mais tempo morto. Os degraus na variável manipulada que foram aplicados a esse sistema são:

- Degrau positivo de 34,2 para 35,0%;
- Degrau positivo de 34,5 para 36,0%;
- Degrau positivo de 34,2 para 37,0%;
- Degrau positivo de 34,6 para 38,0%.

Figura 24: Degraus na variável manipulada na malha aberta de Nível.

Tabela 10: Funções de transferência para a malha aberta de Nível obtidas do pré-teste de identificação.

	Degrau	Função de Transferência	fit
Malha Aberta (Degrau na entrada)	De 34,2 para 35	$G_{MA_34,2_35}(s) = \frac{-13,623e^{-35,93 \cdot s}}{10009 \cdot s + 1}$	97,02 %
	De 34,5 para 36	$G_{MA_34,5_36}(s) = \frac{-16,256e^{-37,00 \cdot s}}{10029 \cdot s + 1}$	99,00 %
	De 34,2 para 37	$G_{MF_34,2_37}(s) = \frac{-12,106e^{-38,01 \cdot s}}{7760 \cdot s + 1}$	97,22 %
	De 34,6 para 38	$G_{MF_34,6_38}(s) = \frac{-12,677e^{-24,64 \cdot s}}{8289 \cdot s + 1}$	98,72 %

5.1.2.2 Pré-teste de identificação da malha fechada de Nível

Para realizar o pré-teste de identificação da malha fechada de nível, o *setpoint* do processo é excitado com um sinal degrau partindo do ponto de operação. Neste caso, o nível começa em 75%, e a variável manipulada em 30%. Na Figura 25 pode-se ver a malha fechada de Nível. Na Tabela 11, é mostrado os parâmetros do controlador PI do Nível. Na Figura 26 mostra-se os pré-testes de identificação da malha fechada de nível. As funções de transferência obtidas do pré-teste de identificação para a malha fechada de nível são mostradas na Tabela 12.

Figura 25: Diagrama de blocos da malha fechada de Nível.

Tabela 11: Parâmetros do controlador PI da malha fechada de Nível.

Parâmetro	K_p	T_i
Valor	5	250

Tabela 12: Funções de transferência para a malha de Nível obtidas do pré-teste de identificação.

	Degrau	Função de Transferência	fit
Malha Fechada (Degrau no SP)	De 30 para 45	$G_{MA_30_45}(s) = \frac{-8,638e^{-34,24 \cdot s}}{10944 \cdot s + 1}$	96,07 %
	De 30 para 60	$G_{MA_30_60}(s) = \frac{-9,679e^{-33,94 \cdot s}}{12956 \cdot s + 1}$	98,39 %
	De 30 para 80	$G_{MA_30_80}(s) = \frac{-10,565e^{-28,01 \cdot s}}{13829 \cdot s + 1}$	98,25 %
	De 80 para 30	$G_{MA_80_30}(s) = \frac{-9,549e^{-10 \cdot s}}{10438 \cdot s + 1}$	98,16 %
	De 60 para 30	$G_{MA_60_30}(s) = \frac{-8,083e^{-13 \cdot s}}{8920 \cdot s + 1}$	98,33 %
	De 45 para 30	$G_{MA_45_30}(s) = \frac{-1,255e^{-26 \cdot s}}{5045 \cdot s + 1}$	93,86 %

(a) De 30% a 45%

(b) De 30% a 60%

(c) De 30% a 80%

(d) De 80% a 30%

(e) De 60% a 30%

(f) De 45% a 30%

Figura 26: Degraus no SP na malha de Nível.

5.1.3 Pré-teste de Identificação da Malha de pH

Na malha de pH, a variável manipulada é a vazão de base, que varia em uma faixa de 0 a 100%. A variável controlada tem uma faixa de 0 a 14 pH. Com o sistema em malha aberta excita-se a planta com diferentes valores no acionamento da bomba de dosagem de solução de base. Para todos os pré-testes de identificação se considera uma vazão constante de ácido de 50 l/h.

5.1.3.1 Pré-teste de Identificação da malha aberta de pH

Neste caso, na malha de pH, encontrou-se muita dificuldade para estabilizar o valor de porcentagem na solução base que consiga atingir o valor de pH, isto porque o valor de pH perto de 7 pH é muito sensível às perturbações no processo, então não se apresentam resultados neste item. Na Figura 27 mostra-se o diagrama de blocos da malha aberta de pH.

Figura 27: Diagrama de blocos da malha aberta de pH.

5.1.3.2 Pré-teste de Identificação da malha fechada de pH

O pré-teste de identificação da malha fechada de pH consiste em excitar o valor de referência da planta em malha fechada e medir os valores de entrada e saída na malha de pH. Tudo isto com o controlador PI funcionando com os parâmetros indicados na Tabela 13. Na Figura 28 mostra-se o diagrama de blocos da malha fechada de pH.

Figura 28: Diagrama de blocos da malha fechada de pH.

Tabela 13: Parâmetros do controlador PI da malha fechada de pH.

Parâmetro	K_p	T_i
Valor	2	180

Na parte de experimentação, a malha fechada de pH é excitada com degraus na seguinte sequência:

- Degrau de 7,0 para 7,5;
- Degrau de 7,0 para 8,0;
- Degrau de 7,0 para 11,0;
- Degrau de 7,0 para 6,5;
- Degrau de 7,0 para 6,0;
- Degrau de 7,0 para 3,0.

Na primeira parte do pré-teste foi testado o processo em malha fechada com degraus positivos e negativos de 0,5 e 1 pH de variação no valor de referência (neste caso começando de um pH igual a 7,0). A saída do controlador PI ajusta a vazão da solução de base através da bomba. Foram coletados 4000 pontos em cada teste com um período de amostragem de 1s. Os gráficos destes testes são mostrados nas Figuras 29a a 29f.

Para cada degrau foram calculadas as funções de transferência com o comando "procest" do Matlab com os dados coletados de entrada e saída. Este comando do Matlab identifica um modelo linear de primeira ordem mais tempo morto, onde se pode selecionar a faixa de valores do ganho, número de polos e a faixa de valores do retardo na entrada. As funções de transferência são mostradas na Tabela 14. Nas Tabelas 15, 16 e 17 mostram-se os parâmetros a serem usados na identificação, calculados a partir dos resultados obtidos no pré-teste de identificação para as três variáveis de controladas.

Para a duração do experimento da identificação não linear das três variáveis foi considerado o critério de (ZHU, 2001) e (VERHAEGEN; VERDULT, 2007). No caso da Temperatura na Tabela mostra-se os tempos calculados a partir da constante de tempo média, em malha aberta de 2730,9 s e em malha fechada de 1977,8 s, considerando suficiente o valor calculado por (ZHU, 2001), foi escolhido uma duração de experimento de 49156 s. Para o nível, foi escolhido o menor dos 4 calculados (103550 s), mas por questões práticas considerou-se um valor de 87238 s. Para o pH, de acordo com (ZHU, 2001), a duração do experimento foi de 15894 s.

(a) de 7,0 para 7,5

(b) de 7,0 para 8,0

(c) de 7,0 para 11,0

(d) de 7,0 para 6,5

(e) de 7,0 para 6,0

(f) de 7,0 para 3,0

Figura 29: Degraus no SP da malha de pH.

Para o cálculo do tempo de amostragem foi considerada a menor das funções de transferência em malha aberta e fechada, ressaltando que o menor período de amostragem é indicado por (ZHU, 2001) para as três variáveis. No experimento foi considerado para a coleta de dados um período de amostragem de 1 s e ele foi se incrementado até encontrar um bom modelo.

Os tempos de *bit* ou chaveamento dos sinais PRBS e GMN foram calculados a partir da menor constante de tempo de cada variável, eles são mostradas na Tabela 17. Durante os testes de identificação eles foram mudando de valor, visando atingir a faixa de operação de cada variável. Os valores finais são mostrados em cada teste de identificação não linear.

Tabela 14: Funções de transferência obtidas no pré-teste de identificação da malha fechada de pH.

Degrau	Função de Transferência	Fit
De 7,0 para 7,5	$G_{MA_7,0_7,5}(s) = \frac{0,19748e^{-27,26 \cdot s}}{395,74 \cdot s + 1}$	62,21 %
De 7,0 para 8,0	$G_{MA_7,0_8,0}(s) = \frac{0,1765e^{-37,17 \cdot s}}{357,97 \cdot s + 1}$	53,3 %
De 7,0 para 11,0	$G_{MA_7,0_11,0}(s) = \frac{0.22649e^{-0.0 \cdot s}}{1540 \cdot s + 1}$	55,75 %
De 7,0 para 6,5	$G_{MA_7,0_6,5}(s) = \frac{0.14625e^{-19,0 \cdot s}}{931,05 \cdot s + 1}$	60,57 %
De 7,0 para 6,0	$G_{MA_7,0_6,0}(s) = \frac{0.12944e^{-33,524 \cdot s}}{738,55 \cdot s + 1}$	72,97 %
De 7,0 para 3,0	$G_{MA_7,0_3,0}(s) = \frac{0.10136e^{-0.0 \cdot s}}{1335.6 \cdot s + 1}$	65,95 %

Fonte: Autor

Tabela 15: Cálculo da duração do experimento para a identificação não linear das três variáveis do processo.

Variável	MA/MF	Média das constantes de tempo	Tempo de acomodação	Duração do experimento (T_e)	
		τ_{med}	$t_s = 3 * \tau_{med}$	(Zhu) $T_e = 6 * t_s$	(Verhaegen) $T_e = 10 * \tau$
Temperatura	MA	2730,9 s	8192,7 s	49156 s	27309 s
	MF	2941,4 s	8824,2 s	52945 s	29414 s
Nível	MA	11524 s	34572 s	207432 s	115240 s
	MF	10355 s	31065 s	186390 s	103550 s
pH	MA	—	—	—	—
	MF	883 s	2649 s	15894 s	8830 s

Fonte: Autor

Tabela 16: Cálculo do período de amostragem para a identificação não linear das três variáveis do processo.

Variável	MA / MF	Menor Constante de tempo	Tempo de acomodação	Período de amostragem T_s		
		τ_{min}	$t_s = 3 * \tau_{max}$	(Zhu)	(Soderström)	(Gustavson)
Temperatura	MA	2586,2 s	$2586,2 * 3 = 7758,6 \text{ s}$	$\frac{7758,6}{100} = 77,59 \text{ s}$	$\frac{7758,6}{10} = 775,86 \text{ s}$	$\frac{2586,2}{10} = 258,62 \text{ s}$
	MF	1977,8 s	$1977,8 * 3 = 5933,4 \text{ s}$	$\frac{5933,4}{100} = 59,33 \text{ s}$	$\frac{5933,4}{10} = 593,34 \text{ s}$	$\frac{1977,8}{10} = 197,78 \text{ s}$
Nível	MA	7760 s	$7760 * 3 = 23280 \text{ s}$	$\frac{23280}{100} = 232,8 \text{ s}$	$\frac{23280}{10} = 2328 \text{ s}$	$\frac{7760}{10} = 776 \text{ s}$
	MF	5045 s	$5045 * 3 = 15135 \text{ s}$	$\frac{15135}{100} = 151,35 \text{ s}$	$\frac{15135}{10} = 1513,5 \text{ s}$	$\frac{5045}{10} = 504,5 \text{ s}$
pH	MA	—	—	—	—	—
	MF	357,97 s	$357,97 * 3 = 1073,91 \text{ s}$	$\frac{1073,91}{100} = 10,74 \text{ s}$	$\frac{1073,91}{10} = 107,39 \text{ s}$	$\frac{357,97}{10} = 35,80 \text{ s}$

Fonte: Autor

Tabela 17: Cálculo do mínimo tempo de *bit* para a identificação não linear das três variáveis do processo.

Variável	MA / MF	Menor constante de tempo (τ_{min})	Período de amostragem (T_s)	Tempo de bit (T_b)
Temperatura	MA	2586,2s	77,59s	$77,59 * 5 = 387,93s$
	MF	1977,8s	59,33s	$59,33 * 5 = 296,67s$
Nível	MA	7760s	232,8s	$232,8 * 5 = 1164s$
	MF	5045s	151,35s	$151,35 * 5 = 756,75s$
pH	MA	—	—	—
	MF	357,97s	10,74s	$10,74 * 5 = 53,70s$

Fonte: Autor

5.2 Testes de Identificação não linear em Malha Aberta

Para identificar os modelos não lineares das três malhas de controle, cada malha foi excitada com um sinal PRBS e GMN em malha aberta e foram coletados os dados na entrada e saída da planta para cada sinal. Os tempos de coleta de dados para a identificação e a validação dos modelos não lineares para as três variáveis do processo em malha aberta são mostrados na Tabela 18. A duração dos experimentos para os testes de identificação é o dobro de tempo que foi usado para os testes de validação para o caso da Temperatura e Nível. No caso do pH foi usada a mesma duração de tempo para identificar e para validar os modelos.

Tabela 18: Duração dos experimentos para identificação e validação do modelos não lineares para as três variáveis em malha aberta.

Variável	Sinal	Modelo	Dados de Identificação	Dados de Validação
Temperatura	PRBS	NARX	49156 s	24578 s
		HW	49156 s	24578 s
	GMN	NARX	49156 s	24578 s
		HW	49156 s	24578 s
Nível	PRBS	NARX	87238 s	43619 s
		HW	87238 s	43619 s
	GMN	NARX	87238 s	43619 s
		HW	87238 s	43619 s
pH	PRBS	NARX	15894 s	15894 s
		HW	15894 s	15894 s
	GMN	NARX	15894 s	15894 s
		HW	15894 s	15894 s

Fonte: Autor.

5.2.1 Identificação não linear em malha aberta de Temperatura

Na malha de temperatura as variáveis manipulada e controlada foram descritas na Subseção 5.1.1, a diferença na coleta de dados está no sinal a ser utilizado para a identificação do modelo não linear, neste caso foram utilizados o PRBS e GMN como sinais de entrada do sistema. Os parâmetros do experimento para coletar os dados são calculados a partir da resposta da curva de reação com sinal degrau, conforme mostrado nas Tabelas 15, 16 e 17.

Para coletar dados de entrada e saída com o sinal **PRBS**, a variável controlada foi inicializada em 36°C e a variável manipulada em 54%. A amplitude do sinal PRBS foi considerada 16% para cima e para abaixo, valor que fazia que a temperatura no tanque de reação atingisse valores ao redor de 36°C, sem atingir o limite de operação de 45°C. Os

parâmetros do sinal PRBS são mostrados na Tabela 19. Na Figura 30 mostra-se a forma de onda e o espectro de potência do sinal **PRBS** e os dados coletados para a identificação com este sinal são mostrados na Figura 31.

Tabela 19: Parâmetros do teste de identificação não linear da malha aberta de Temperatura com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de Amostragem	1	s	T_s
Tempo de Bit	830	s	T_b
Duração do experimento	49156	s	T_e
Amplitude do sinal PRBS	+/-16	%	a

Fonte: Autor.

Figura 30: Sinal PRBS e seu espectro de potência para o teste de identificação não linear da malha aberta de temperatura.

Para coletar dados de entrada e saída com sinal **GMN**, a malha de temperatura opera segundo as mesmas condições que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 20, a forma de onda do sinal e seu espectro de potência são mostrados na Figura 32. Os dados coletados do teste de identificação não linear para a malha aberta de Temperatura com sinal GMN são mostrados na Figura 33.

Figura 31: Dados coletados de entrada e saída no teste de identificação não linear para a malha aberta de Temperatura com sinal PRBS.

Tabela 20: Parâmetros do teste de identificação não linear da malha aberta de Temperatura com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Tempo de amostragem	1	s	T_s
Tempo de chaveamento	830	s	T_{ch}
Duração do experimento	49156	s	T_e
Amplitude do sinal GMN	+/-15	%	a

Fonte: Autor.

Figura 32: Forma de onda e espectro de potência do sinal GMN para identificar a malha aberta de temperatura.

5.2.1.1 Modelos NARX da malha aberta de temperatura

Os modelos NARX de temperatura são calculados com os dados coletados de entrada-saída, as funções não lineares obtidas com os sinais PRBS e GMN são apresentadas nas

Figura 33: Dados coletados de entrada e saída no teste de identificação não linear para a malha aberta de Temperatura com sinal GMN.

Equações 5.2 e 5.3, respectivamente.

$$\begin{aligned}
 y(k) = & 0,3143 * y(k-1) + 0,2318 * u(k-1) - 0,6434x10^{-3} * y(k-2)^3 \\
 & - 0,5514x10^{-4} * u(k-1)^3 + 0,5423x10^{-3} * y(k-3) * y(k-2)^2 \\
 & + 0,6001x10^{-4} * u(k-2) * u(k-1) * y(k-2) \\
 & + 0,1844x10^{-4} * u(k-3) * y(k-3)^3 \\
 & - 0,2128x10^{-4} * u(k-2) * u(k-1) * y(k-1) \\
 & - 0,5002x10^{-4} * u(k-2) * u(k-1) * y(k-3) \\
 & + 0,2088x10^{-3} * u(k-1) * u(k-1) * y(k-3) \\
 & - 0,3707x10^{-3} * u(k-1) * y(k-3) * y(k-2) \\
 & + 0,1308x10^{-4} * u(k-3) * u(k-1) * y(k-3) \\
 & - 0,1130x10^{-4} * u(k-3) * u(k-3) * y(k-1) \\
 & + 0,6493x10^{-5} * u(k-2) * u(k-1) * u(k-1) \\
 & + 0,3998x10^{-1} * y(k-2) * y(k-1) \\
 & - 0,1695x10^{-1} * y(k-3) * y(k-1)
 \end{aligned} \tag{5.2}$$

$$\begin{aligned}
y(k) = & 0,1254x10^1 * y(k-1) + 0,2103x10^{-4} * u(k-1)^3 \\
& -0,7319x10^{-2} * u(k-1) * y(k-2) \\
& -0,2699x10^{-4} * u(k-1) * u(k-1) * y(k-3) \\
& -0,3350x10^{-2} * y(k-3) * y(k-3) \\
& -0,1531x10^{-3} * u(k-1) * y(k-3) * y(k-3) \\
& -0,6914x10^{-4} * u(k-2) * y(k-3) * y(k-2) \\
& +0,2461x10^{-4} * u(k-2) * u(k-1) * y(k-2) \\
& -0,8947x10^{-5} * u(k-2)^3 + 0,2822 * y(k-2)
\end{aligned} \tag{5.3}$$

5.2.1.2 Modelos de Hammerstein-Wiener da malha aberta de temperatura

Os modelos de Hammerstein-Wiener da malha de temperatura obtidos no teste de identificação não linear em malha aberta com sinais PRBS e GMN são mostrados nas Figuras 34 e 35, respectivamente.

Figura 34: Modelo de Hammerstein-Wiener para a malha aberta de Temperatura excitada com sinal PRBS.

Figura 35: Modelo de Hammerstein-Wiener para a malha aberta de Temperatura excitada com sinal GMN.

5.2.2 Identificação não linear para a malha aberta de Nível

No teste de identificação não linear da malha aberta de nível, ela é excitada pelos sinais PRBS e GMN. Para realizar o teste com sinal **PRBS** consideram-se os parâmetros do sinal mostrados na Tabela 21, a forma de onda e o espectro de potência desse sinal é mostrado na Figura 36. Os gráficos dos dados coletados para a identificação não linear com sinal PRBS são mostrados na Figura 37.

Para coletar os dados de entrada e saída com o sinal **GMN**, as condições de operação são as mesmas que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 22, a forma de onda e o espectro de potência desse sinal são mostrados na Figura 38, e os dados coletados do teste de identificação são mostrados na Figura 39.

Tabela 21: Parâmetros do teste de identificação não linear da malha aberta de Nível com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de Bit	1450	s	T_b
Duração do experimento	87238	s	T_e
Amplitude do sinal PRBS	$\pm 2,5$	%	a

Fonte: Autor.

Figura 36: Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha aberta de Nível.

Figura 37: Dados coletados de entrada e saída no teste de identificação não linear com sinal PRBS para a malha aberta de Nível.

Tabela 22: Parâmetros do teste de identificação não linear da malha aberta de Nível com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de chaveamento	1450	s	T_{ch}
Duração do experimento	87238	s	T_e
Amplitude do sinal GMN	+/-2.5	%	a

Fonte: Autor.

Figura 38: Forma de onda e espectro de potência do sinal GMN usado para identificar a malha aberta de Nível.

Figura 39: Dados coletados de entrada e saída no teste de identificação não linear com sinal GMN para a malha aberta de Nível.

5.2.2.1 Modelos NARX da malha aberta de Nível

Os modelos NARX com os dados coletados para o teste de identificação não linear para a malha aberta de nível com os sinais PRBS e GMN são mostrados nas Equações (5.4) e (5.5).

$$\begin{aligned}
y(k) = & 0,9286 + 1,0032 * y(k-1) + 0,3358x10^{-4} * u(k-1)^2 * y(k-1) \\
& + 0,6741x10^{-4} * u(k-1)^3 + 0,5448x10^{-5} * u(k-3) * u(k-1)^2 \\
& + 0,2886 * y(k-2) + 0,1582x10^{-3} * u(k-1) * y(k-3) * y(k-2) \\
& - 0,5913x10^{-2} * u(k-1) * y(k-3) \\
& + 0,2080x10^{-4} * u(k-1) * y(k-3)^2 - 0,2864x10^{-2} * y(k-1)^2 \\
& - 0,2063x10^{-3} * u(k-1)^2 * y(k-2) \\
& - 0,2338x10^{-2} * y(k-3) * y(k-2)
\end{aligned} \tag{5.4}$$

$$\begin{aligned}
y(k) = & -7,4229 + 2,7504 * y(k-1) - 1,1777 * y(k-2) \\
& - 0,1082x10^{-2} * u(k-3) * u(k-2)^2 \\
& + 0,9399x10^{-4} * u(k-3) * u(k-1)^2 - 0,2788x10^{-1} * u(k-1) * y(k-1) \\
& - 0,2788x10^{-1} * u(k-1) * y(k-1) - 1,0440 * u(k-3) \\
& + 0,7189x10^{-1} * u(k-3) * u(k-2) \\
& + 0,2722x10^{-3} * u(k-1)^2 * y(k-2) - 0,1515x10^{-4} * y(k-3)^3 \\
& + 0,9187x10^{-4} * u(k-1) * y(k-3) * y(k-2) \\
& - 0,4450x10^{-4} * u(k-3) * y(k-3) * y(k-1)
\end{aligned} \tag{5.5}$$

5.2.2.2 Modelos de Hammerstein-Wiener da malha aberta de Nível

Os modelos de Hammerstein-Wiener da malha aberta de Nível, obtidos no teste de identificação não linear com sinais PRBS e GMN são mostrados nas Figuras 40 e 41, respectivamente.

Figura 40: Modelo de Hammerstein-Wiener para a malha aberta de Nível obtido com sinal PRBS.

Figura 41: Modelo de Hammerstein-Wiener para a malha aberta de Nível obtido com sinal GMN.

5.2.3 Identificação não linear para a malha aberta de pH

No teste de identificação não linear para a malha aberta de pH, a entrada do sistema é excitada pelos sinais PRBS e GMN. Apesar de no pré-teste de identificação em malha aberta do pH não ter sido obtida uma função de transferência FOPDT, foram usados os resultados obtidos dos pré-testes de identificação em malha fechada para identificar os modelos não lineares, isto, para verificar se com um sinal de excitação PRBS ou GMN se consegue melhorar o desempenho dos modelos não lineares obtidos em malha fechada.

Para realizar esse teste com sinal **PRBS** consideram-se os parâmetros do sinal mostrados na Tabela 23, a forma de onda e o espectro de potência desse sinal são mostrados na Figura 42. O gráfico dos dados coletados para a identificação não linear com sinal PRBS é mostrados na Figura 43.

Para coletar dados de entrada e saída com o sinal **GMN**, as condições de operação são as mesmas que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 24, a forma de onda e o espectro de potência desse sinal são mostrados na Figura 44 e os dados coletados do teste de identificação são mostrados na Figura 45.

Tabela 23: Parâmetros do teste de identificação não linear da malha aberta de pH com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de Bit	260	s	T_b
Duração do experimento	15894	s	T_e
Amplitude do sinal PRBS	+/-10	%	a

Fonte: Autor.

Figura 42: Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha aberta de pH.

Figura 43: Dados coletados de entrada e saída do teste de identificação não linear da malha aberta de pH com sinal PRBS.

5.2.3.1 Modelos NARX para a malha aberta de pH

Os modelos NARX obtidos do teste de identificação não linear para a malha aberta de pH com os sinais PRBS e GMN são mostrados nas Equações (5.6) e (5.7), respectivamente.

Tabela 24: Parâmetros do teste de identificação não linear da malha aberta de pH com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de chaveamento	520	s	T_{ch}
Duração do experimento	15894	s	T_e
Amplitude do sinal GMN	+/-6	%	a

Fonte: Autor.

Figura 44: Forma de onda e espectro de potência do sinal GMN usado para identificar a malha aberta de pH.

Figura 45: Dados coletados de entrada e saída para a malha aberta de pH do teste de identificação não linear com sinal GMN.

$$\begin{aligned}
y(k) = & -8,1635 * y(k-1) + 2,3514 * u(k-1) \\
& -0,3001 * u(k-1) * y(k-1) \\
& +1,4137 * y(k-1)^2 - 0,0538 * y(k-3) * y(k-1)^2 \\
& +0,4775x10^{-2} * u(k-1) * y(k-3) * y(k-2) \\
& +0,0001 * y(k-1)^2 * u(k-2) \\
& +0,2282 * y(k-3)^3 - 0,0464 * y(k-1)^3 \\
& +0,0111 * u(k-1) * y(k-1)^2 \\
& -0,1422x10^{-2} * u(k-3) * u(k-2) * y(k-3) \\
& -0,5661x10^{-3} * u(k-3) * u(k-2) * y(k-1) \\
& -0,5966 * y(k-3)^2 * y(k-2) \\
& +0,1944x10^{-2} * u(k-3) * u(k-2) * y(k-2) \\
& +0,4822 * y(k-3) * y(k-2) * y(k-2) \\
& +0,0926 * y(k-3) * y(k-2) * y(k-1) \\
& -0,1667 * y(k-2)^3 - 0,0386 * u(k-1) * y(k-3) \\
& -0,1748x10^{-3} * u(k-1)^3
\end{aligned} \tag{5.6}$$

$$\begin{aligned}
y(k) = & 1,0520 * y(k-1) - 0,0616 * y(k-3) \\
& +1,5526x10^{-6} * u(k-1) * u(k-3)^2 \\
& -0,0002 * u(k-1) * u(k-2) * y(k-3) + 0,0005 * y(k-2)^2 \\
& +0,0001 * u(k-1) * u(k-2) * y(k-2)
\end{aligned} \tag{5.7}$$

5.2.3.2 Modelos de Hammerstein-Wiener da malha aberta de pH

Os modelos de Hammerstein-Wiener da malha aberta de pH obtidos com sinais PRBS e GMN são mostrados nas Figuras 46 e 47, respectivamente.

Figura 46: Modelo de Hammerstein-Wiener para a malha aberta de pH obtido com sinal PRBS.

Figura 47: Modelo de Hammerstein-Wiener para a aberta malha de pH obtido com sinal GMN.

5.3 Testes de Identificação não linear em Malha Fechada

Nestes testes, o *setpoint* de cada malha é excitado com sinais PRBS e GMN, de forma a não saturar a variável manipulada e controlada. A justificativa para realizar testes de identificação em malha fechada é verificar se eles têm melhor desempenho que no caso dos testes realizados em malha aberta.

5.3.1 Identificação não linear para a malha fechada de Temperatura

A malha fechada de Temperatura é testada excitando seu *setpoint* e medindo as variáveis controlada e manipulada na saída e entrada do processo, respectivamente.

Para coletar os dados de entrada e saída com sinal **PRBS**, os parâmetros desse sinal são mostrados na Tabela 25 e a forma de onda do sinal e seu espectro de potência são mostrados na Figura 48. Os dados coletados do teste de identificação não linear com sinal PRBS são mostrados na Figura 49.

Tabela 25: Parâmetros do teste de identificação não linear da malha fechada de Temperatura com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de bit	830	s	T_b
Duração do experimento	49156	s	T_e
Amplitude do sinal PRBS	+/-5	%	a

Fonte: Autor.

Figura 48: Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha fechada de Temperatura.

Figura 49: Dados coletados de entrada e saída do teste de identificação não linear da malha fechada Temperatura com sinal PRBS.

Para coletar dados de entrada e saída com sinal **GMN**, a malha de temperatura opera sob as mesmas condições que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 26, a forma de onda do sinal e seu espectro de potência e os dados coletados com este sinal são mostrados nas Figuras 50 e 51, respectivamente.

Tabela 26: Parâmetros do teste de identificação não linear da malha fechada de Temperatura com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de chaveamento	830	s	T_{ch}
Duração do experimento	49156	s	T_e
Amplitude do sinal GMN	± 5	%	a

Fonte: Autor.

Figura 50: Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de Temperatura.

Figura 51: Dados coletados de entrada e saída do teste de identificação não linear da malha fechada Temperatura com sinal GMN.

5.3.1.1 Modelos NARX para a malha fechada de Temperatura

Os modelos NARX da malha de fechada de temperatura a partir do teste de identificação são calculados com os dados coletados de entrada-saída, as funções não lineares

polinomiais obtidas com sinais PRBS e GMN são mostradas nas Equações (5.8) e (5.9), respectivamente.

$$\begin{aligned}
 y(k) = & 1,1068 * y(k-1) + 0,6468x10^{-5} * u(k-1)^3 \\
 & + 0,3496x10^{-4} * y(k-2)^3 + 0,2209x10^{-4} * u(k-1) * y(k-3)^2 \\
 & - 0,5774x10^{-2} * u(k-2) \\
 & - 0,4948x10^{-2} * y(k-2)^2 \\
 & - 0,1442x10^{-4} * u(k-1)^2 * y(k-3)
 \end{aligned} \quad (5.8)$$

$$\begin{aligned}
 y(k) = & 1,1064 * y(k-1) + 0,6634x10^{-5} * u(k-1)^3 \\
 & - 0,5197x10^{-2} * y(k-2)^2 + 0,1881x10^{-4} * u(k-1) * y(k-3)^2 \\
 & - 0,1468x10^{-4} * u(k-1)^2 * y(k-1) + 0,4252x10^{-4} * y(k-2)^2 * y(k-1)
 \end{aligned} \quad (5.9)$$

5.3.1.2 Modelos de Hammerstein-Wiener da malha fechada de temperatura

Os modelos de Hammerstein-Wiener obtidos para a malha fechada de Temperatura excitando o valor de referência com sinais PRBS e GMN são mostrados nas Figuras 52 e 53, respectivamente.

Figura 52: Modelo de Hammerstein-Wiener para a malha de Temperatura com sinal PRBS.

Figura 53: Modelo de Hammerstein-Wiener para a malha de Temperatura com sinal GMN.

5.3.2 Identificação não linear para a malha fechada de Nível

O teste de identificação não linear da malha de fechada de Nível é realizado excitando o *setpoint* do nível no tanque de reação e medindo as variáveis controlada e manipulada na saída e entrada da planta, respectivamente.

Para coletar os dados de entrada e saída para a identificação da malha fechada de nível com sinal **PRBS**, os parâmetros desse sinal são mostrados na Tabela 27 e a forma de onda do sinal e seu espectro de potência são mostrados na Figura 54. Os dados coletados com sinal PRBS são mostrados na Figura 55.

Tabela 27: Parâmetros do teste de identificação não linear da malha fechada de Nível com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de bit	1450	s	T_b
Duração do experimento	87238	s	T_e
Amplitude do sinal PRBS	+/-20	%	a

Fonte: Autor.

Figura 54: Forma de onda e seu espectro de potência do sinal PRBS usado para identificar a malha fechada de Nível.

Para coletar os dados de entrada e saída para o teste de identificação não linear com sinal **GMN**, a malha fechada de nível opera sob as mesmas condições que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 28 e a forma de onda do sinal e seu espectro de potência são mostrados na Figura 56. Os dados coletados com sinal GMN são mostrados na Figura 57.

Figura 55: Dados coletados de entrada e saída do teste de identificação não linear com sinal PRBS para a malha fechada de Nível.

Tabela 28: Parâmetros do teste de identificação não linear da malha fechada de Nível com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de chaveamento	1450	s	T_{ch}
Duração do experimento	87238	s	T_s
Amplitude do sinal GMN	+/-20	%	T_s

Fonte: Autor.

Figura 56: Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de Nível.

5.3.2.1 Modelos NARX para a malha fechada de Nível

Os modelos NARX da malha fechada de nível obtido do teste de identificação não linear com sinal de referência excitado com sinais PRBS e GMN são mostrados nas Equações

Figura 57: Dados coletados de entrada e saída do teste de identificação não linear com sinal GMN para a malha fechada de Nível.

ções (5.10) e (5.11), respectivamente.

$$\begin{aligned}
 y(k) = & 0,2506 + 1,3677 * y(k-1) \\
 & -0,2322 * y(k-2) - 0,3048x10^{-6} * u(k-1) * y(k-3) * y(k-2) \\
 & -0,1783x10^{-6} * u(k-3) * y(k-1)^2 + 0,3034x10^{-4} * u(k-3)^2 \\
 & +0,2608x10^{-5} * u(k-1)^3 \\
 & -0,3797x10^{-3} * u(k-1)^2 \\
 & +0,4954x10^{-2} * u(k-1) - 0,2061x10^{-6} * u(k-2)^3 \\
 & -0,1362 * y(k-3)
 \end{aligned} \tag{5.10}$$

$$\begin{aligned}
 y(k) = & 1,3819 * y(k-1) + 0,6830x10^{-4} * u(k-1) * y(k-1)^2 \\
 & -0,1333x10^{-5} * u(k-3)^2 * y(k-2) \\
 & -0,5933x10^{-2} * u(k-1) * y(k-1)^2 - 0,6938x10^{-2} * y(k-1)^2 \\
 & +0,6318x10^{-5} * u(k-1)^2 * y(k-2) - 0,1949x10^{-5} * u(k-1)^2 * u(k-2) \\
 & -0,2819x10^{-5} * u(k-3)^2 * u(k-1) \\
 & -0,8242x10^{-3} * u(k-3)^2 + 0,9105x10^{-5} * u(k-3)^3 \\
 & +0,1464x10^{-4} * u(k-3) * y(k-1)^2 + 0,2526x10^{-5} * u(k-3) * u(k-2)^2
 \end{aligned} \tag{5.11}$$

5.3.2.2 Modelos de Hammerstein-Wiener para a malha fechada de Nível

Os modelos de Hammerstein-Wiener da malha fechada do nível obtidos dos testes de identificação não linear com sinais PRBS e GMN são mostrados nas Figuras 58 e 59, respectivamente.

Figura 58: Modelo de Hammerstein-Wiener da malha fechada de Nível com sinal PRBS.

Figura 59: Modelo de Hammerstein-Wiener da malha fechada de Nível com sinal GMN.

5.3.3 Identificação não linear para a malha fechada de pH

O teste de identificação não linear da malha fechada de pH é realizado excitando o *setpoint* do pH no tanque de reação e medindo as variáveis controlada e manipulada na saída e entrada da planta respectivamente.

Para coletar os dados de entrada e saída para o teste de identificação não linear, o *setpoint* foi excitado com sinal **PRBS**. Os parâmetros do sinal PRBS são mostrados na Tabela 29, a forma de onda do sinal e seu espectro de potência são mostrados na Figura 60. Os dados coletados com sinal PRBS são mostrados na Figura 61.

Tabela 29: Parâmetros do teste de identificação não linear da malha fechada de pH com sinal PRBS.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de bit	130	s	T_b
Duração do experimento	15894	s	T_e
Amplitude do sinal PRBS	+/-2	%	a

Fonte: Autor.

Figura 60: Forma de onda e espectro de potência do sinal PRBS usado para identificar a malha fechada de pH.

Figura 61: Dados de entrada e saída coletados do teste de identificação não linear excitado com sinal PRBS para a malha fechada de pH.

Para coletar os dados de entrada e saída com sinal **GMN**, a malha de pH opera sob as mesmas condições que no caso com sinal PRBS. Os parâmetros do sinal GMN são mostrados na Tabela 30, a forma de onda do sinal e seu espectro de potência são

mostrados na Figura 50.

Tabela 30: Parâmetros do teste de identificação não linear da malha fechada pH com sinal GMN.

Parâmetro	Valor	Unidade	Símbolo
Intervalo de amostragem	1	s	T_s
Tempo de chaveamento	260	s	T_{ch}
Duração do experimento	15894	s	T_e
Amplitude do sinal GMN	+/-3	%	a

Fonte: Autor.

Figura 62: Forma de onda e espectro de potência do sinal GMN usado para identificar a malha fechada de pH.

Figura 63: Dados coletados de entrada e saída do teste de identificação não linear da malha fechada de pH excitada com sinal GMN.

5.3.3.1 Modelos NARX para a malha fechada de pH

Os modelos NARX da malha fechada de pH obtidos do teste de identificação não linear excitados com sinais PRBS e GMN são mostrados nas Equações (5.12) e (5.13), respectivamente.

$$\begin{aligned}
y(k) = & 8,94 - 0,14121x10^{-1} * u(k-2) * y(k-2) \\
& - 0,1028x10^{-4} * u(k-3)^2 * u(k-1) \\
& + 0,1678x10^{-2} * u(k-2) * y(k-3) * y(k-1) \\
& + 0,8532x10^{-3} * u(k-3) * u(k-1) * y(k-1) \\
& + 0,8532x10^{-3} * u(k-3) * u(k-1) * y(k-1) \\
& \quad - 0,2923x10^{-4} * u(k-1)^3 \\
& - 0,1784x10^{-2} * u(k-3) * y(k-3) * y(k-1) \\
& \quad + 0,2833x10^{-3} * u(k-3)^2 * y(k-3) \\
& + 0,5311x10^{-3} * u(k-2) * u(k-1) * y(k-2) \\
& - 0,5124x10^{-3} * u(k-2) * u(k-1) * y(k-1) \\
& \quad - 0,7321x10^{-2} * u(k-3) * u(k-1) \\
& \quad + 0,1836x10^{-4} * u(k-3) * u(k-1)^2 \\
& \quad + 0,5997x10^{-5} * u(k-3) * u(k-1)^2 \\
& - 0,1252x10^{-2} * u(k-1) * y(k-3) * y(k-1) \\
& \quad - 0,1175x10^{-3} * u(k-3)^2 * y(k-1) \\
& + 0,3992x10^{-2} * u(k-1)^2 - 0,7310x10^{-1} * u(k-1)
\end{aligned} \tag{5.12}$$

$$\begin{aligned}
y(k) = & 15,082 + 0,9109 * u(k-2) \\
& -0,3103x10^{-1} * y(k-2)^2 * y(k-1) \\
& +0,1093x10^{-1} * u(k-2) * y(k-2)^2 \\
& -0,3734x10^{-1} * y(k-1) - 0,1342x10^{-2} * u(k-3) * y(k-3)^2 \\
& +0,4346x10^{-3} * u(k-3)^2 * y(k-3) \\
& +0,2175x10^{-1} * y(k-2) * y(k-1)^2 \\
& -0,1626x10^{-2} * u(k-3) * y(k-3) * y(k-2) \\
& -0,3970x10^{-4} * u(k-3)^2 * u(k-1) \\
& -0,1989 * u(k-2) * y(k-2) + 0,4424 * y(k-2) * y(k-1) \\
& +0,2674x10^{-3} * u(k-1)^2 * y(k-1) - 0,2067x10^{-2} * u(k-1)^2
\end{aligned} \tag{5.13}$$

5.3.3.2 Modelos de Hammerstein-Wiener da malha fechada de pH

Os modelos de Hammerstein-Wiener obtidos do teste de identificação não linear excitados com sinais PRBS e GMN para a malha fechada de pH são mostrados nas Figuras 64 e 65, respectivamente.

Figura 64: Modelo de Hammerstein-Wiener para a malha fechada de pH obtido com sinal PRBS.

Figura 65: Modelo de Hammerstein-Wiener para a malha fechada de pH obtido com sinal GMN.

5.4 Validação dos Modelos não lineares

Nesta seção os modelos não lineares NARX e Hammerstein-Wiener obtidos para as três malhas de controle são validados usando a validação cruzada. A duração do experimento para coletar os dados de validação foi considerada como a metade da duração do experimento para coletar os dados de identificação. Para identificar o melhor modelo foi usado o índice *fit* para avaliar e comparar os modelos resultantes de cada teste em malha aberta e malha fechada, com sinais GMN e PRBS. Os índices *fit* dos modelos de Hammerstein-Wiener e NARX são mostrados nas Tabelas 31 e 32, respectivamente.

Na Tabela 31 observa-se que para o caso da variável de temperatura, o maior *fit* foi obtido quando o sistema foi excitado em malha aberta com o sinal PRBS. No bloco não linear de entrada foi usado o *deadzone* e no bloco de saída não linear foi o *sigmoide*, e para o bloco linear as ordens foram $nb = 4, nf = 8, nk = 2$. Na variável nível, o maior *fit* foi obtido quando o sistema foi excitado em malha fechada com sinal PRBS, no bloco não linear de entrada foi empregado o *sigmoide* e no bloco de saída não linear foi o *pwnlinear*, e para o bloco linear as ordens foram $nb = 6, nf = 8, nk = 3$. Por último, na variável pH, o maior *fit* foi obtido quando o sistema foi excitado em malha aberta com sinal GMN, no bloco não linear de entrada foi utilizado o *saturation* e no bloco de saída não linear foi o *deadzone*, e para o bloco linear as ordens foram $nb = 4, nf = 5, nk = 3$.

Na Tabela 32 observam-se os índices *fit* para os modelos NARX. Para o caso da temperatura, o melhor modelo foi obtido quando a malha foi excitada com sinal GMN em malha fechada, com 6 regressores e com um período de amostragem de 153 s. Na variável nível, o melhor modelo foi obtido quando o sistema foi excitado com sinal PRBS em malha aberta, com doze regressores e período de amostragem de 26 s. Por último, na variável pH o melhor modelo obtido foi quando o sistema foi excitado com sinal PRBS em malha aberta, com dezoito regressores e período de amostragem de 177 s.

Tabela 31: Fits dos modelos de Hammerstein-Wiener para as três variáveis em malha aberta e em malha fechada.

Variável	Sinal	Modelo	Estrutura na Entrada	Ordem do Modelo linear	Estrutura na saída	Maior Fit
Temperatura	PRBS	HW - MA	Deadzone	nb=4, nf=8, nk=2	Sigmoide	95,68 %
		HW - MF	Saturation	nb=3, nf=7, nk=1	Pwlinear	58,53 %
	GMN	HW - MA	Sigmoide	nb=4, nf=8, nk=2	Pwlinear	87,27 %
		HW - MF	Saturation	nb=6, nf=7, nk=2	Saturation	77,52 %
Nível	PRBS	HW - MA	Sigmoide	nb=5, nf=7, nk=3	Pwlinear	77,27 %
		HW - MF	Sigmoide	nb=6, nf=8, nk=3	Pwlinear	79,35 %
	GMN	HW - MA	Sigmoidnet	nb=4, nf=6, nk=2	Sigmoidnet	17,18 %
		HW - MF	Deadzone	nb=1, nf=8, nk=3	Deadzone	11,21 %
pH	PRBS	HW -MA	Deadzone	nb=2, nf=4, nk=1	Sigmoidnet	43,14 %
		HW - MF	Saturation	nb=6, nf=8, nk=1	Deadzone	51,75 %
	GMN	HW - MA	Saturation	nb=4, nf=5, nk=3	Deadzone	77,76 %
		HW - MF	Deadzone	nb=4, nf=7, nk=1	Deadzone	44,95 %

Fonte: Autor.

5.4.1 Validação dos modelos da malha de Temperatura

Para realizar a validação dos **modelos de Hammerstein-Wiener** foi considerado um novo grupo de dados coletados (de acordo com a Seção 5.4) em malha aberta e fechada com sinais PRBS e GMN, respectivamente. Os resultados desta validação para os modelos obtidos são mostrados nas Figuras 66a, 66b, 66c e 66d. Para o caso da validação dos modelos **NARX** foi considerado o mesmo cenário que o dos quatro modelos de Hammerstein-Wiener e as validações são mostradas nas Figuras 67a, 67b, 67c, 67d.

5.4.2 Validação dos modelos da malha de Nível

Os resultados da validação dos modelos de Hammerstein-Wiener da malha de Nível são apresentados nas Figuras 68a, 68b, 68c e 68d e dos modelos NARX são mostrados nas Figuras 69a, 69b, 69c e 69d.

Tabela 32: Fits dos modelos NARX para as três variáveis em malha aberta e em malha fechada.

Variável	Sinal	Malha de Controle	Número de regressores	Período de amostragem para o modelo	Maior Fit
Temperatura	PRBS	Malha aberta	16	37 s	90,9 %
		Malha Fechada	32	12 s	66,86 %
	GMN	Malha Aberta	11	25 s	96,74 %
		Malha Fechada	7	153 s	64,13 %
Nível	PRBS	Malha Aberta	12	26 s	96,78 %
		Malha Fechada	10	17 s	87,46 %
	GMN	Malha Aberta	12	292 s	10,16 %
		Malha Fechada	12	156 s	67,71 %
pH	PRBS	Malha Aberta	18	177 s	73,99 %
		Malha Fechada	17	7 s	68,64 %
	GMN	Malha Aberta	12	8s	52,22 %
		Malha Fechada	14	73 s	58,47 %

Fonte: Autor.

5.4.3 Validação dos modelos da malha de pH

Nas Figuras 70a, 70b, 70c e 70d mostram-se as validações cruzadas dos modelos Hammerstein-Wiener com sinais PRBS e GMN para a malha aberta e fechada de pH. As validações cruzadas dos modelos NARX são mostradas nas Figuras 71a, 71b, 71c e 71d.

5.4.4 Resultados das validações

Para o caso das validações dos modelos de Hammerstein-Wiener observa-se nas Figuras 66b, 68a e 68b que esses modelos apresentam picos que estão relacionados com a escolha dos parâmetros dos blocos não lineares na entrada e saída dos modelos não lineares.

Para o caso específico dos modelos de Hammerstein-Wiener de Nível o período de amostragem foi iniciado com 150 segundos, posteriormente foi-se diminuindo esse período e observou-se que o valor do índice *fit* não diminuía significativamente.

(a) Malha aberta com sinal PRBS

(b) Malha aberta com sinal GMN

(c) Malha fechada com sinal PRBS

(d) Malha fechada com sinal GMN

Figura 66: Validação dos Modelos HW para a Temperatura.

(a) Malha Aberta com sinal PRBS

(b) Malha Aberta com sinal GMN

(c) Malha Fechada com sinal PRBS

(d) Malha Fechada com sinal GMN

Figura 67: Validação dos Modelos NARX para a Temperatura.

(a) Malha Aberta com sinal PRBS.

(b) Malha Aberta com sinal GMN.

(c) Malha Fechada com sinal PRBS.

(d) Malha Fechada com sinal GMN.

Figura 68: Validação dos Modelos HW para o Nível.

(a) Malha Aberta com sinal PRBS

(b) Malha Aberta com sinal GMN

(c) Malha Fechada com sinal PRBS

(d) Malha Fechada com sinal GMN

Figura 69: Validação dos Modelos NARX para o Nível.

(a) Malha Aberta com sinal PRBS

(b) Malha Aberta com sinal GMN

(c) Malha Fechada com sinal PRBS

(d) Malha Fechada com sinal GMN

Figura 70: Validação dos Modelos HW do pH.

(a) Malha Aberta com sinal PRBS

(b) Malha Aberta com sinal GMN

(c) Malha Fechada com sinal PRBS

(d) Malha Fechada com sinal GMN

Figura 71: Validação dos Modelos NARX do pH.

6 CONCLUSÕES E TRABALHOS FUTUROS

Neste capítulo são apresentadas as conclusões e elas são divididas em três partes, as relativas aos pré-testes de identificação, testes de identificação não linear e modelos não lineares.

6.1 Pré-testes de Identificação

Nos pré-testes de identificação anotaram-se as seguintes conclusões:

- Para os cálculos de duração do experimento foi considerada a função de transferência que tinha a menor constante de tempo.
- Verificou-se que as funções de transferência de primeira ordem mais tempo morto dos pré-testes em malha aberta deram constantes de tempo maiores comparadas com as funções de transferência obtidas em malha fechada, de acordo com o que se esperava.
- Para a variável temperatura observa-se que o ganho da função de transferência é positivo, no caso do nível é negativo e no caso do pH é positivo, indicado que as ações destas plantas seriam direta, indireta e direta, respectivamente.
- No caso da variável nível a normalização dos dados coletados ajudou a melhorar o *fit* da FOPDT, sem normalizar se teve dificuldades para identificar o modelo FOPDT.
- O ganho e o tempo de acomodação não foram utilizados para projetar os parâmetros do sinal de excitação a ser usado para identificar o modelo.

6.2 Identificação não linear

Nesta seção são apresentadas as seguintes conclusões:

- Para realizar testes de identificação é importante ter uma ideia do comportamento dinâmico dos processos.
- Foram realizados os pré-testes para cada um dos três processos e encontradas as respectivas funções de transferência de primeira ordem mais tempo morto, essa primeira aproximação dos processos foi usada para estimar os parâmetros dos testes de identificação não linear.
- Foram realizados testes de identificação não linear com sinais de entrada PRBS e GMN em malha aberta e malha fechada. Foram obtidos os modelos não lineares para cada uma das entradas.
- O sinal GMN consegue excitar o sistema em malha aberta em baixas frequências em comparação com o sinal PRBS. O sinal PRBS muda de um nível máximo ao mínimo pelo que ele consegue excitar as respostas de dinâmica rápida, enquanto o sinal GMN tem a possibilidade de se manter na mesma direção de excitação e com isto não excitar a planta com dinâmicas rápidas.

6.3 Modelos não lineares

Nesta seção são apresentadas as seguintes conclusões:

- Foram identificados os modelos não lineares NARX e de Hammerstein-Wiener para o processo de neutralização de pH.
- Realizou-se a validação cruzada dos modelos obtidos e foram calculados os índices Fit para cada um deles. De acordo com os Fits calculados, os melhores modelos não lineares HW e NARX foram identificados com sinal PRBS para a temperatura; PRBS para o Nível; GMN para o pH.
- Os modelos HW foram mais fáceis de obter através de um algoritmo recursivo, isto comparado com os modelos NARX que tiveram mais variedade quanto à quantidade de regressores a serem testados.
- Foi verificado que variando o período de amostragem também variam os modelos obtidos.
- As ordens dos modelos da parte linear para as estruturas de Hammerstein-Wiener não necessariamente são idênticas quando o sistema a ser identificado é excitado com sinais PRBS e GMN, tanto em malha aberta como em malha fechada.

6.4 Trabalhos Futuros

Após ter realizado este trabalho de pesquisa, ficaram vários temas por revisar dentro da teoria de identificação de sistemas não lineares. A seguir são apresentadas algumas perspectivas sobre os trabalhos futuros que poderiam ser realizados:

- Obter modelos NARMAX das três variáveis de controle e compará-las com os modelos obtidos nesta pesquisa.
- Obter os modelos NARX e Hammerstein-Wiener com sinais de entrada do tipo soma de senóides.
- Obter os modelos NARX e Hammerstein-Wiener considerando o caso MIMO, onde uma entrada ou saída de uma malha de processo está acoplada com as saídas das outras malhas de processo.
- Projetar e implementar um controlador MPC não linear baseado em modelos NARX e Hammerstein-Wiener usando os modelos não lineares obtidos. Comparar o desempenho desse controlador com um controlador preditivo linear ou um controlador preditivo multimodelos.
- Realizar testes de identificação não linear usando a teoria de aprendizado de máquina, *Data Driven* e redes neurais.
- Realizar uma pesquisa sobre a análise de resíduos dos modelos não lineares para identificar as razões de porque os dados coletados para a identificação não conseguiram identificar a dinâmica das malhas do processo.
- A configuração dos parâmetros dos blocos não lineares (*pwnlinear*, *sigmoidnet*, *saturation*, *deadzone* e *wavenet*) dos modelos de Hammerstein-Wiener poderia ser uma boa opção para melhorar os modelos, neste trabalho não foi estudada em profundidade as 5 estruturas não lineares mencionadas na Seção 4.4.
- Usar o critério de Akaike para determinar as ordens dos modelos.
- Aplicar outras formas de avaliar os modelos não lineares diferente do índice *fit*.
- Usar os dados coletados para ajustar os parâmetros dos modelos com o objetivo de reduzir a variância dos parâmetros estimados.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDULLAH, N.; KARSITI, M.; IBRAHIM, R. A review of ph neutralization process control. In: *IEEE 4th International Conference on Intelligent and Advanced Systems*. [S.l.: s.n.], 2012. p. 594–598.
- AGUIRRE, L. *Identificação de sistemas - Técnicas Lineares e não Lineares aplicadas a sistemas reais*. 4. ed. Belo Horizonte, Brasil: UFMG, 2015.
- AKAIKE, H. A new look at statistical model identification. *IEEE Trans. On Automatic Control*, v. 19, n. 6, p. 716–723, 1974.
- ALVARADO, C. *Identificação e controle preditivo de uma planta piloto de neutralização de pH*. Dissertação de Mestrado — Escola Politécnica da USP. Departamento de Telecomunicações e Controle, 2013.
- ALVARADO, C. *Estudo e implementação de métodos de validação de modelos matemáticos aplicados no desenvolvimento de sistemas de controle de processos industriais*. Tese de Doutorado — Escola Politécnica da USP. Departamento de Telecomunicações e Controle, 2017.
- ASTROM, K.; BOHLIN, T. Numerical identification of linear dynamic system from normal operating records. In: *In Proceeding of IFAC Symposium on Self-Adaptive System*. [S.l.: s.n.], 1965.
- BASSO, M. et al. Narx models of an industrial power plant gas turbine. *IEEE Transactions on Control Systems Technology*, v. 13, n. 4, p. 599–604, 2005.
- BEQUETTE, B. W. Nonlinear Control of Chemical Processes: A Review. *Ind. Eng. Chem. Res.*, v. 30, n. 7, p. 1391–1413, 1991.
- BILLINGS, S. *Nonlinear system identification : NARMAX methods in the time, frequency and spatio-temporal domains*. 1. ed. Londres: John Wiley and Sons, 2013.
- CAMACHO, E.; BORDONS, C. *Model Predictive Control*. Londres, UK: Springer-Verlag, 1999.
- CHEN, S. et al. Practical Identification of Narmax models using radial basis functions. *Int. J. Control*, n. 52(6), p. 1327–1350, 1990.
- CHEN, S.; BILLINGS, S.; LUO, W. Orthogonal least squares methods and their application to nonlinear system identification. *Int. J. Control*, n. 50(5), p. 1873–1896, 1989.
- DIAZ, H.; DESROCHERS, A. Modeling of non-linear discrete-time systems from input-output data. *IEEE Signal Processing Letters*, v. 24, n. 5, p. 629–641, 1988.

- DRIDI, N.; HADZAGIC, M. Akaike and bayesian information criteria for hidden markov models. *IEEE Signal processing letters*, v. 26, n. 2, p. 302–306, 2019.
- ESMAEILANI, L.; GHASARI, J.; BAGHERZADEH, M. Bayesian approach to identify hammerstein–wiener non-linear model in presence of noise and disturbance. *IET Control Theory & Applications*, v. 13, n. 3, p. 367–376, 2019.
- EYKHOFF, P. *System Identification: Parameter and state estimation*. 1. ed. London, UK: John Wiley, 1974.
- FALKNER, A. Iterative technique in the identification of a non-linear system. *INT. J. CONTROL*, v. 48, n. 1, p. 385–396, 1988.
- FAVARO, J. *Controle preditivo aplicado à planta piloto de neutralização de pH*. Dissertação de Mestrado — Escola Politécnica da EPUSP. Departamento de Engenharia de Telecomunicações e Controle, 2012.
- FLAVOREA, S. *Identificação de um processo de neutralização de pH vias redes neurais*. Dissertação de Mestrado — Escola Politécnica da EPUSP. Departamento de Engenharia de Telecomunicações e Controle, 1997.
- GARCIA, C. *Modelagem e Simulação*. 2. ed. São Paulo, Brasil: Editora da USP, 2005.
- GARCIA, C.; MORARI, M. Internal model control. 1. a unifying review and some new results. *Ind. Eng. Chem. Process Des. Dev.*, v. 21, n. 2, p. 308–323, 1982.
- GOMEZ, J.; JUTAN, A.; BAEYENS, E. Wiener model identification and predictive control of a ph neutralization process. *IEE Proc.-Control Theory Appl.*, v. 151, n. 3, p. 329–338, 2004.
- GUSTAFSSON, T. et al. Modeling of pH for Control. *Ind. Eng. Chem. Res.*, v. 34, n. 3, p. 820–827, 1995.
- GUSTAFSSON, T.; WALLER, K. Nonlinear and Adaptive Control of pH. *Ind. Eng. Chem. Res.*, v. 31, n. 12, p. 2681–2693, 1992.
- GUSTAFSSON, T. K. Calculation of the pH Value of a Mixture of Solutions – An Illustrations of the Use of Chemical Reaction Invariants. *Chemical Engineering Science*, v. 37, n. 9, p. 1419–1421, 1982.
- HABER, R.; UNBEHAUEN, H. Structure identification on nonlinear dynamic systems - a survey on input-iutput approaches. *Automatica*, v. 26, n. 4, p. 651–677, 1990.
- HENSON, M. A.; SEBORG, D. E. Adaptive Nonlinear Control of a pH Neutralization Process. *IEEE Transactions on Control Systems Technology*, v. 2, n. 3, p. 169–182, 1994.
- IBRAHIM, R. *Practical Modelling and Control Implementation Studies on a pH Neutralization Process Pilot Plant*. Tese de Doutorado — University of Glasgow, 2008.
- JACOBS, O.; HEWKIN, P.; WHILE, C. Online computer control of ph in an industrial process. In: *IEE Proceedings D - Control Theory and Applications*. [S.l.: s.n.], 1980. v. 127, n. 4, p. 161–168.

- JERÔNIMO, R. A. *Identificação não linear de um processo de neutralização de pH multivariável utilizando modelos polinomiais*. Dissertação de Mestrado — Escola Politécnica da USP. Departamento de Engenharia de Telecomunicações e Controle, 1998.
- JUTILA, P.; ORAVA, P. J.; SALMELIN, B. A Physico-Chemical Model and Simulation of pH-Process in Continuous Stirred Tank Reactors. *Mathematics and Computers in Simulation*, v. 23, n. 2, p. 99–106, 1981.
- JUTILA, P.; VISALA, A. Pilot Plant Testing of an Adaptive pH-Control Algorithm Based on Physico-Chemical Modelling. *Mathematics and Computers in Simulation*, v. 26, n. 6, p. 523–533, 1984.
- KHALIL, H. K. *Nonlinear System*. 3. ed. Upper Saddle River, New Jersey: Prentice Hall, 2002.
- KORENBERG, M. et al. An orthogonal Parameter estimation algorithm for nonlinear stochastic systems. In: *International Journal of Control*. [S.l.: s.n.], 1988. v. 1, n. 48, p. 193–210.
- KURAMOTO, A. S. R. *Projeto de Sinais de Excitação para Identificação Multivariável de Plantas Industriais*. Tese de Doutorado — Escola Politécnica da USP. Departamento de Engenharia de Telecomunicações e Controle, 2012.
- LARROTTA, F. *Estudo e implementação de sinais de excitação aplicados em identificação de sistemas multivariáveis*. Dissertação — Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle., 2015.
- LEONTARITIS, I.; BILLINGS, S. Input-output parametric models for non-linear systems Part I: Deterministic Non-linear Systems. *International Journal of Control*, v. 41, n. 2, p. 303–328, 1985a.
- LEONTARITIS, I.; BILLINGS, S. Input-output parametric models for non-linear systems Part II: Stochastic non-linear systems. *International Journal of Control*, v. 41, n. 2, p. 329–344, 1985b.
- LEONTARITIS, I.; BILLINGS, S. Experimental design and identifiability for non-linear systems. *International Journal System of Science*, v. 18, n. 1, p. 189–202, 1987.
- LI, F.; JIA, L. Parameter estimation of hammerstein-wiener nonlinear system with noise using special test signals. *Mechanical Systems and Signal Processing*, v. 117, p. 483–497, 2019.
- LI, G. et al. Identification of a class of nonlinear autoregressive models with exogenous inputs based on kernel machines. *IEEE TRANSACTIONS ON SIGNAL PROCESSING*, v. 59, n. 5, p. 2146–2159, 2011.
- LJUNG, L. *System Identification Theory for the User*. 2. ed. Upper Saddle River, NJ, EUA: Prentice Hall, 1999.
- MARQUES, F. *Modelagem de uma planta piloto de neutralização de pH utilizando uma combinação das abordagens fenomenológica e empírica*. Dissertação de Mestrado — Escola Politécnica da USP. Departamento de Engenharia de Telecomunicações e Controle, 2014.

- MCAVOY, T.; HSU, E.; LOWENTHAL, S. Dynamic of pH in Controlled Stirred Tank Reactor. *Ind. Eng. Chem. Process Des. Develop.*, v. 11, n. 4, p. 68–70, 1972a.
- MCAVOY, T. J. Time Optimal and Ziegler-Nichols Control Experimental and Theoretical Results. *Ind. Eng. Chem. Process Des. Develop.*, v. 11, n. 1, p. 71–78, 1972b.
- NARENDRA, K.; GALLMAN, P. An interative method for the identification of nonlinear systems using a hammerstein model. *IEEE Transactions on Automatic Control*, v. 11, n. 3, p. 546–44, 1966.
- NIJMEIJER, H.; SCHAFT, A. van der. *Nonlinear Dynamical Control Systems*. 1. ed. New York, NY, EUA: Springer, 1990.
- PAJUNEN, G. Comparison of Linear and Nonlinear Adaptive Control of a pH-Process. *IEEE Control Systems Magazine*, v. 7, n. 1, p. 39–44, 1987.
- PRÖLL, T.; KARIM, M. N. Model-predictive ph control using real-time narx approach. *AIChE Journal*, v. 40, n. 2, p. 269–282, 1994.
- PêS, B. d. S. et al. A hammerstein–wiener model for single-electron transistors. *IEEE TRANSACTIONS ON ELECTRON DEVICES*, v. 66, n. 2, p. 1092–1099, 2019.
- RICHALET, J. et al. Model Predictive Heuristic Control: Applications to Industrial Processes. *Automática*, v. 14, p. 413–428, 1978.
- RODRIGUEZ, O. *Pré-processamento de dados na identificação de processos industriais*. Dissertação — Universidade de São Paulo. Departamento de Engenharia Elétrica., 2015.
- ROMANO, R. *Identificação de processos não-lineares e quantificação de atrito em válvulas de controle*. Tese de Doutorado — Escola Politécnica da USP. Departamento de Telecomunicações e Controle, 2010.
- SEBORG, D. A perspective on advanced strategies for process control.modelling, identification and control. v. 15, n. 3, p. 179–189, 1994.
- SEBORG, D.; EDGAR, T.; MELLICHAMP, D. *Process Dynamics and Control*. 3. ed. New York, USA: John Wiley, 2010.
- SEGHOUANE, A. Model selection criteria for image restoration. *IEEE Transactions on Neural Networks*, v. 20, n. 8, p. 1357–1363, 2009.
- SLOTINE, J.-J.; LI, W. *Applied Nonlinear Control*. 1. ed. Englewood Cliffs, New Yersey, USA: Prentice Hall, 1991.
- SODERSTROM, T.; STOICA, P. *System Identification*. 1. ed. Hemel Hempstead, U.K: Prentice Hall, 1989.
- SUNG, S. W.; LEE, I.-B. pH Control Using a Simple Set Point Change. *Ind. Eng. Chem. Res.*, v. 34, n. 5, p. 1730–1734, 1995a.
- SUNG, S. W.; LEE, I.-B. pH Control Using an Identification Reactor. *Ind. Eng. Chem. Res.*, v. 34, n. 7, p. 2418–2426, 1995b.

VARGAS, L. *Controle preditivo adaptativo não linear aplicado a um processo de neutralização de pH*. Dissertação de Mestrado — Escola Politécnica da USP. Departamento de Telecomunicações e Controle, 1999.

VERHAEGEN, M.; VERDULT, V. *Fitering and System Identification*. 1. ed. Cambridge, England: Cambridge University Press, 2007.

VIDYASAGAR, M. *Nonlinear System Analysis*. 2. ed. Englewood Cliffs, New Jersey: Prentice Hall, 1993.

WANG, D.-Q.; DING, F. Hierarchical least squares estimation algorithm for hammerstein–wiener systems. *IEEE Signal Processing Letters*, v. 19, n. 12, p. 825–828, 2012.

WESTWICK, D. T. et al. Using decoupling methods to reduce polynomial narx models. *IFAC-PapersOnLine*, v. 51, n. 15, p. 796–801, 2018.

WILLS, A. et al. Identification of hammerstein–wiener models. *Automatica*, v. 49, n. 1, p. 70–85, 2013.

WORDEN, K. et al. On the confidence bounds of gaussian process narx models and their higher-order frequency response functions. *Mechanical Systems and Signal Processing*, v. 104, p. 188–223, 2018.

WRIGHT, R. A.; KRAVARIS, C. On-Line Identification and Nonlinear Control of an Industrial pH Process. *Journal of Process Control*, v. 11, n. 4, p. 361–374, 2001.

WRIGHT, R. A.; SOROUSH, M.; KRAVARIS, C. Strong Acid Equivalent Control of pH Processes: An Experimental Study. *Ind. Eng. Chem. Res.*, v. 30, n. 11, p. 2437–2444, 1991a.

ZANABRIA, O. *Modelamento, Simulação e Controle de um Processo de Neutralização de pH*. Dissertação de Mestrado — Escola Politécnica da USP. Departamento de Telecomunicações e Controle, 1997.

ZHU, Y. (Ed.). *Multivariable System Identification for Process Control*. 1. ed. Kidlington, Oxford OX5 1GB, UK: Elsevier Science Ltd, 2001.

ZMARZLY, D.; FRACZ, P. Nonlinear modeling of streaming electrification measured in swinging cylinder system. *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 23, n. 1, p. 174–182, 2016.

APÊNDICE A – CÁLCULO DE CONCENTRAÇÕES

A.1 Cálculo da concentração de Solução Base

Para calcular a concentração molar da solução Base a partir de um valor de pH desejado, neste caso $pH = 12,27$, calcula-se primeiro o valor de pOH dessa solução Base com:

$$pOH = 14,00 - pH \quad (A.1)$$

Depois calcula-se o valor de $pOH = 14,00 - 12,27 = 1,73$, então a concentração molar dessa solução base desejada de acordo com a Equação (A.2) é igual 0,0186 mol/l.

$$[pOH] = 10^{-1,73} = 0,0186 \left[\frac{\text{mol}}{\text{l}} \right] \quad (A.2)$$

Usando-se a Equação (A.3), calcula-se o quantidade de moles, multiplicando a concentração de $[OH]$ pelo volume (180 l), o qual é igual a 3,3480 moles.

$$n[OH^-] = [OH^-] * V(mol) = 0,0186 * 180 = 3,3480 [\text{mol}] \quad (A.3)$$

Para calcular a quantidade de massa requerida, usa-se a Equação (A.4), resultando em 134,0703 g.

$$massa[OH^-] = n[OH^-] * MM = 3,3480 * 40 = 133,92 [\text{g}] \quad (A.4)$$

Dividindo-se esta massa pela porcentagem de pureza de $NaOH$ (0,97%) a massa final requerida de $NaOH$ é $\frac{133,92}{0,97} = 138,06\text{g}$.

A.2 Cálculo da concentração da Solução Ácida

Para calcular a concentração da solução Ácida forte a partir de um valor desejado, neste caso de $pH = 2,25$, usa-se a Equação (A.5), resultando em uma concentração de

0,0056 mol/litro.

$$[H^+] = 10^{-2,25} = 0,0056 \frac{\text{mol}}{\text{l}} \quad (\text{A.5})$$

Usando-se a Equação (A.6), calcula-se a quantidade de moles multiplicando a concentração de $[H^+]$ pelo volume, o qual é igual a $n[H^+] = 1,0080$ moles.

$$n[H^+] = [H^+] * V = 0,0056 * 180 = 1,0080 [\text{mol}] \quad (\text{A.6})$$

Para calcular a quantidade de massa requerida, usa-se a Equação (A.7). O que dá uma massa de 36,75 gramas.

$$\text{massa}[H^-] = n[H^+] * MM = 1,0080 * 36,46 = 36,75 [\text{g}] \quad (\text{A.7})$$

Para calcular o volume da solução ácida através da Equação (A.8), divide-se essa massa pela massa específica do HCl, o que dá um valor de 30,88 ml.

$$\text{Volume}[H^-] = \frac{\text{massa}[H^-]}{\rho_{HCl}} = \frac{36,75}{1,19} = 30,88 [\text{ml}] \quad (\text{A.8})$$

Finalmente, dividindo esse valor pela porcentagem de concentração da solução HCl a ser usada, resulta em $\frac{30,88}{0,37} = 83,46$ ml.