



UFBA

UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS GRADUAÇÃO EM
ENGENHARIA INDUSTRIAL - PEI

Mestrado Acadêmico em Engenharia Industrial

Emanuel Benício de Almeida Cajueiro

**Inferindo Posição e Carga de Haste Polida de
Bombeio Mecânico a partir de Corrente de Saída
de Inversor de Frequência**



**Salvador
2012**

EMANUEL BENÍCIO DE ALMEIDA CAJUEIRO

**INFERINDO POSIÇÃO E CARGA DE HASTE POLIDA DE BOMBEIO
MECÂNICO A PARTIR DA CORRENTE DE SAÍDA DE INVERSOR DE
FREQUÊNCIA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Industrial, da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Industrial.

Orientadores: Prof. Dr. Ricardo de Araújo Kalid.
Prof. Dr. Leizer Schnitman.

Salvador
2012

C139 Cajueiro, Emanuel Benício de Almeida
Inferindo posição e carga de haste polida de bombeio
mecânico a partir de corrente de saída de inversor de
frequência / Emanuel Benício de Almeida Cajueiro. – Salvador,
2012.

137 f. : il. color.

Orientador: Prof. Doutor Ricardo de Araújo Kalid

Coorientador: Leizer Schnitman

Dissertação (mestrado) – Universidade Federal da Bahia.
Escola Politécnica, 2012.

1. Petróleo. 2. Sistemas não-lineares. 3. Redes neurais
(computação). I. Kalid, Ricardo de Araújo. II. Schnitman,
Leizer. III. Universidade Federal da Bahia. IV. Título.


CDD: 623.1

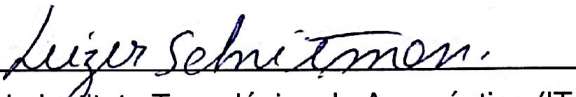
**INFERINDO POSIÇÃO E CARGA DE HASTE POLIDA DE BOMBEIO
MECÂNICO A PARTIR DA CORRENTE DE SAÍDA DE INVERSOR DE
FREQUÊNCIA**


Emanuel Benício De Almeida Cajueiro

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Industrial, da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Industrial.

Banca Examinadora

Ricardo de Araújo Kalid - Orientador 
Doutor em Engenharia Química pela Universidade de São Paulo (USP), Brasil.
Universidade Federal da Bahia.

Leizer Schnitman - Orientador 
Doutor em Engenharia Elétrica pelo Instituto Tecnológico da Aeronáutica (ITA),
Brasil.
Universidade Federal da Bahia.

Manuel de Almeida Barreto Filho 
Doutor em Engenharia de Petróleo pela The University of Texas at Austin, Estados
Unidos.
PETROBRAS S/A.

Luis Antonio Aguirre 
Doutor em Engenharia de Controle pela University of Sheffield, Inglaterra.
Universidade Federal de Minas Gerais.

A Soane Benício, minha linda esposa, pelo amor, companheirismo e apoio.

A Edvaldo Benício e Reinalice Benício, meus pais, por serem maravilhosos.

Aos meus irmãos, Nazareno, Agno, Sanmaria e Santana, pelo amor e carinho.

Às minhas avós Alice e Lindaura, e a minha sobrinha Mariana.

AGRADECIMENTOS

Agradeço ao Senhor Deus, por sempre estar comigo, mesmo sem eu merecê-lo, por me capacitar, ajudar e fortalecer.

Agradeço ao Prof. Kalid e ao Prof. Leizer, pelas orientações para a condução deste trabalho; por acreditarem em mim; pelas horas investidas durante a revisão desta dissertação e dos artigos associados a este trabalho; e pela imensa paciência.

Ao Prof. Cristiano Fontes, pela confiança e pelo excelente suporte dado aos pesquisadores do PEI.

Ao amigo e colega de pesquisa Cícero Brandão, pela sugestão do tema, pelas conversas, discussões pertinentes e por toda ajuda com a parte experimental do trabalho.

Ao Eng. Attilio Triggia, pela revisão do texto no capítulo relacionado ao bombeio mecânico e por toda colaboração.

Aos amigos e colegas de pesquisa Thiago, Lairton e Antônio Claudio pelas discussões pertinentes e por todo auxílio com a parte experimental.

Ao Prof. Aguirre e ao Eng. Barreto por aceitarem fazer parte da banca examinadora.

Aos funcionários da secretaria do PEI, Tatiane e Robinson, pela dedicação dada aos alunos do programa.

Aos colegas do PEI.

CAJUEIRO, E. B. A. **Inferindo Posição e Carga de Haste Polida de Bombeio Mecânico a partir de Corrente de Saída de Inversor de Frequência**. 137 f. il. 2012. Dissertação (Mestrado). Escola Politécnica, Universidade Federal da Bahia, Salvador.

RESUMO

A carta dinamométrica de superfície (CDS) é importante para o diagnóstico das condições operacionais de poços de petróleo em terra (*on-shore*) que tem como método de elevação artificial o bombeio mecânico (BM). A CDS é constituída por um traçado contínuo de dados de posição *versus* carga suportada pela haste polida durante um ciclo de bombeio. Tais dados, geralmente, são adquiridos no campo por meio de sensores físicos de carga e posição. Neste trabalho, técnicas de identificação de sistemas dinâmicos lineares e não-lineares são aplicadas a fim de inferir posição e carga dinâmica de haste polida de BM, a partir da corrente elétrica de saída de um inversor de frequência usado no acionamento e controle de um motor de indução pertencente ao BM. O modelo autoregressivo com entradas exógenas (ARX) foi usado para a abordagem de identificação linear; para a abordagem de identificação não-linear, a qual apresentou resultados melhores do que a linear, foram utilizados o modelo não-linear ARX (NARX) e o modelo de Hammerstein-Wiener, ambos tendo como função não-linear a *wavelet network*. Os resultados obtidos na etapa de validação demonstram que a estratégia é aplicável para as condições operacionais normal e de pancada de fluido, o que tornou possível inferir a CDS sem o uso dos sensores de carga e posição.

Palavras-Chave: identificação de sistemas dinâmicos, *wavelet network*, modelo NARX, modelo de Hammerstein-Wiener, bombeio mecânico, carta dinamométrica de superfície.

CAJUEIRO, E. B. A. **Inferring polished rod load and position from electrical output current of AC drive.** 137 f. il. 2012. Master's Thesis. Escola Politécnica, Universidade Federal da Bahia, Salvador.

ABSTRACT

Position and dynamic load data from polished rod of sucker-rod pumping are significantly important to the diagnosis of oil wells operating conditions. Such data are, often, obtained on field by using physical sensors of load and position. From the electric current seen on a AC drive which activates the induction motor of a pumping unit, this work applies models of identification of linear and nonlinear dynamic systems to infer position and load on the polished rod of sucker-rod pumping equipped wells. For tackling linear identification, the autoregressive model with exogenous input (ARX) was used. On the other hand, for tackling nonlinear identification, the nonlinear ARX (NARX) and the Hammerstein-Wiener models were used, both of them with wavelet network as nonlinear function. The outcomes from the validation step show that the strategy is applicable at some operating conditions, which has allowed the attainment of the surface dynamometer card without using the load and position sensors.

Key-words: system identification, wavelet network, NARX model, Hammerstein-Wiener model, sucker rod pumping, surface dynamometer card.

LISTA DE ILUSTRAÇÕES

Figura 2.1 Identificação caixa preta a batelada de sistemas dinâmicos.	24
Figura 2.2 O ciclo de identificação de sistemas	25
Figura 2.3: Estrutura do modelo ARX.....	33
Figura 2.4 Estrutura geral do modelo não-linear ARX (NARX).....	36
Figura 2.5 Modelo de Hammerstein-Wiener.....	38
Figura 3.1 Função wavelet (ψ) de Haar.....	46
Figura 3.2 Função wavelet (ψ) de Morlet.	47
Figura 3.3 Plano tempo-frequência para a transformada por janela de Fourier	50
Figura 3.4 Funções de base wavelet cobrindo o plano tempo-escala.....	51
Figura 3.5 Estutura geral da wavelet network.	56
Figura 3.6 Função wavelet ψ	61
Figura 3.7 Estrutura da wavelet network.	64
Figura 4.1 Componentes principais do bombeio mecânico.	66
Figura 4.2 Partes da bomba de fundo.	67
Figura 4.3 Ciclo de bombeio.....	68
Figura 4.4 Carta dinamométrica de superfície (CDS).....	69
Figura 4.5 Carta dinamométrica típica de poços rasos	70
Figura 4.6 CDF de um SBM operando sob condição normal.	71
Figura 4.7 Carta dinamométrica associada à condição de pancada de fluido...	72
Figura 5.1 Poço desenvolvido para testes.....	75
Figura 5.2 Unidade de bombeio instalada UFBA	75
Figura 5.3 Célula de carga e do potenciômetro instalados na haste polida.	77
Figura 5.4 Configuração de hardware	79
Figura 5.5 Etapas de planejamento de experimento.	80
Figura 5.6 Vetores de corrente para diferentes condições de carga	81

Figura 5.7 Circuito simplificado equivalente de um motor de indução AC.....	82
Figura 5.8 Nível do anular e variação de CPM da UB.....	85
Figura 5.9 Janela de dados amostrados de posição e carga da haste polida ...	86
Figura 5.10 Cartas dinamométricas registradas.....	87
Figura 5.11 Janela de 100 s de dados de tensão de saída do inversor.	87
Figura 5.12 Dados de corrente de torque e corrente de saída do inversor	88
Figura 5.13 Ciclo de identificação de sistemas.....	89
Figura 5.14 Triagem do sinal de entrada para a identificação.....	91
Figura 5.15 Triagem do sinal de entrada para a identificação.....	92
Figura 5.16 Triagem do sinal de entrada para a identificação.....	94
Figura 5.17 Espectro de amplitude de lado único do sinal de posição.....	95
Figura 5.18 Espectro do sinal de corrente de saída do inversor.	96
Figura 5.19 Sinal de corrente de saída do inversor após filtragem	97
Figura 5.20 Dados para a estimação e validação para a posição.....	99
Figura 5.21 Dados para a estimação e validação para a carga	100
Figura 6.1 Desempenho da estimação do modelo ARX pelo critério FPE.	102
Figura 6.2 Desempenho da estimação do modelo ARX pelo critério FPE	103
Figura 6.3 Desempenho da estimação do modelo ARX pelo critério FPE	104
Figura 6.4 Identificação da posição.....	106
Figura 6.5 Sinal de resíduo para o modelo M1.....	106
Figura 6.6 Identificação da posição.....	108
Figura 6.7 Identificação da posição.....	108
Figura 6.8 Resultado da validação cruzada para o modelo CL1.....	111
Figura 6.9 Resultado da validação cruzada para o modelo MHW5.....	114
Figura 6.10 Sinal de resíduos para o modelo MHW5.....	115
Figura 6.11 Procedimento para uso do modelo de HW com o ARX.....	116

Figura 6.12 Estrutura HW-ARX-1	117
Figura 6.13 Comparação entre a saída medida e a saída simulada	118
Figura 6.14 Resultado do cálculo dos resíduos.....	118
Figura 6.15 Comparação entre a saída medida e a saída simulada	119
Figura 6.16 Comparação entre a saída medida e a saída simulada	120
Figura 6.17 Estrutura geral usada na geração da carta dinamométrica.....	121
Figura 6.18 Carta dinamométrica a partir da corrente de saída do inversor....	122
Figura 6.19 Carta dinamométrica a partir da corrente de saída do inversor....	123

LISTA DE TABELAS

5.1 Especificações do motor de indução rotor tipo gaiola

6.1 Resultado da estimação do modelo ARX

LISTA DE QUADROS

2.1 Modelos Lineares Típicos

5.1 Especificações da célula de carga usada na UB

5.2 Especificações do potenciômetro multivoltas usado na UB

6.1 Resultado das estimativas e validação dos modelos ARX

6.2 Resultado das estimativas e validação dos modelos NARX

6.3 Resultado das estimativas e validação dos modelos NARX

6.4 Resultado da estimação do modelo ARX

6.5 Resultado da estimação do modelo ARX

LISTA DE ABREVIATURAS E SIGLAS

AC	Corrente alternada
ARX	Modelo Autoregressivo com Entradas Exógenas
ARMAX	Modelo Autoregressivo com Entradas Exógenas e Média Móvel
BJ	Modelo de Box-Jenkins
BM	Bombeio Mecânico
CAN	<i>Controller Area Network</i>
CLP	Controlador Lógico Programável
CPM	Ciclo por Minuto
CRA	Análise da Correlação
CWT	Transformada Wavelet Contínua
DC	Corrente Contínua
DWT	Transformada Wavelet Discreta
EPT	Curso Efetivo do Pistão
ENR	Taxa de Máximo Ruído
FCC	Função de Correlação Cruzada
FPE	Função Penalidade ou Desvio de Previsão Final de Akaike
FIR	Resposta ao Impulso Finita
IP	<i>Internet Protocol</i>
LEA	Laboratório de Elevação Artificial
MAC	Controle de Acesso ao Meio
max	Máximo
MPT	Curso Máximo do Pistão
NARX	Modelo Não-Linear Autoregressivo com Entradas Exógenas

OE	Modelo do Desvio na Saída
OPC	<i>Open Productivity and Connectivity</i>
PWM	Modulação por Largura de Pulso
RNA	Rede Neural Artificial
TCP	<i>Transmission Control Protocol</i>
UB	Unidade de Bombeio
WFT	Transformada de Fourier por Janelas

LISTA DE SÍMBOLOS

a	Parâmetro de dilatação
b	Parâmetro de translação
d	Dimensão de entrada
m	Passo de dilatação
n	Passo de translação
ψ	Função wavelet mãe
φ	Função wavelet pai
θ	Coefficientes de modelo linear
Γ	Resultado da decomposição QR
ε	Resíduo
ω	Frequência angular
ω_s	Frequência de amostragem
A	Limite superior do <i>frame</i>
B	Limite inferior do <i>frame</i>
Q	Matriz ortogonal
R	Matriz triangular superior
V	Função penalidade
L^2	Espaço de Lebesgue ou espaço das funções quadrado-integráveis.
T_s	Período de amostragem
N	Comprimento da amostra de dados
b_τ	Coefficientes do filtro da resposta ao impulso finita
na	Número de auto-regressores ou ordem de polinômio $A(q)$
nb	Número de regressores exógenos ou ordem de polinômio $B(q)$
nc	Ordem do polinômio $C(q)$

nd	Ordem do polinômio $D(q)$
nk	Número de atrasos
f	Função
n_F	Ordem do modelo FIR ou ordem de polinômio de equação geral
n_θ	Número de parâmetros estimados
I_M	Corrente produtora de fluxo
I_R	Corrente produtora de torque
I_S	Corrente estatórica
$y(k)$	Sinal discreto medido de saída
\hat{y}	Saída estimada
k	Tempo discreto
$h(q)$	Função de transferência do sistema
$x(k)$	Vetor de entradas
\hat{r}_u	Função de autocorrelação
\hat{r}_{uy}	Função de correlação cruzada
$u(k)$	Sinal discreto medido de entrada

SUMÁRIO

1	INTRODUÇÃO	19
1.1	JUSTIFICATIVA	20
1.2	OBJETIVO GERAL.....	21
1.3	OBJETIVO ESPECÍFICO	21
2	IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS	22
2.1	O CICLO DE IDENTIFICAÇÃO DE SISTEMAS	24
2.1.1	Planejamento de experimento para identificação de sistemas	26
2.1.2	Triagem/Escolha do Sinal de Entrada.....	28
2.1.3	Pré-processamento dos dados	30
2.1.4	Determinação/Escolha da Estrutura Linear.....	31
2.1.4.1	Modelo ARX	33
2.1.5	Determinação/Escolha da Estrutura Não-Linear.....	34
2.1.5.1	Modelo NARX.....	35
2.1.5.2	Modelo de Hammerstein-Wiener.....	37
2.1.6	Determinação da ordem do modelo	38
2.1.7	Estimação de Parâmetros	40
2.1.8	Validação do modelo.....	43
2.2	CONSIDERAÇÕES FINAIS DO CAPÍTULO	45
3	WAVELET NETWORK.....	46
3.1	HISTÓRIA DAS WAVELETS.....	46
3.2	O QUE É A <i>WAVELET</i> ?	48
3.3	TRANSFORMADA DE FOURIER E WAVELET	49
3.4	A TRANSFORMADA WAVELET DISCRETA.....	52
3.5	WAVELET FRAMES	52

3.5.1	Wavelet Frames Radiais	53
3.6	WAVELET CONTÍNUA E DISCRETA PARA DIMENSÕES ALTAS ...	54
3.7	WAVELET NETWORK.....	55
3.7.1	Construção da Wavelet Network.....	56
3.7.2	Procedimento para inicialização e treinamento.....	58
3.8	CONSIDERAÇÕES FINAIS DO CAPÍTULO	64
4	BOMBEIO MECÂNICO E CARTAS DINAMOMÉTRICAS	65
4.1	COMPONENTES Do BOMBEIO MECÂNICO	65
4.2	CICLO DE BOMBEIO	67
4.3	CARTA DINAMOMÉTRICA.....	68
4.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	72
5	MATERIAIS E MÉTODOS	74
5.1	CONJUNTO EXPERIMENTAL	74
5.1.1	O poço e o sistema de bombeio mecânico	74
5.1.2	Célula de carga e o potenciômetro	76
5.1.3	Configuração do hardware.....	78
5.2	PLANEJAMENTO DE EXPERIMENTO.....	79
5.3	APLICAÇÕES DO CICLO DE IDENTIFICAÇÃO.....	88
5.3.1	Triagem/Escolha do Sinal de Entrada.....	90
5.4	PRÉ-PROCESSAMENTO DOS DADOS.....	95
6	RESULTADOS E DISCUSSÃO	101
6.1	IDENTIFICAÇÃO POSIÇÃO <i>VERSUS</i> - CORRENTE.....	101
6.1.1	Análise Preliminar: Estimando o modelo linear ARX	101
6.1.2	Estimando o modelo NARX	107
6.2	IDENTIFICAÇÃO PARA CORRENTE <i>VERSUS</i> CARGA.....	109
6.2.1	Análise Preliminar: Estimando o modelo linear ARX para carga ..	109

6.2.2	Identificando o modelo de Hammerstein-Wiener	112
6.2.3	Aumentando o ajuste dado pelo modelo MHW5.....	115
6.3	GERAÇÃO DA CARTA DINAMOMÉTRICA.....	121
7	CONCLUSÕES, RECOMENDAÇÕES E SUGESTÕES	124
	REFERÊNCIAS	127
	LISTA DE PULBLICAÇÕES	1367

1 INTRODUÇÃO

Quando a construção de modelos matemáticos baseados na modelagem fenomenológica é inviável, e quando dados experimentais de entrada(s) e saída(s) estão disponíveis, um modelo empírico pode ser capaz de representar o comportamento dinâmico de um sistema (SÖDERSTRÖM e STOICA, 1989). Este tipo de modelagem é conhecido como identificação de sistemas caixa-preta e tem sido amplamente estudado e aplicado ao longo das últimas décadas (SÖDERSTRÖM e STOICA, 1989; JUDITSKY, 1995; SAFAVI E ROMAGNOLI, 1996; LJUNG, 1998; AGUIRRE, 2000; NELLES, 2001; KARNY e PAVELKOVA, 2007; ISERMANN E MÜNCHHOF, 2010; LIN, HSU e CHUNG, 2012; CAJUEIRO, KALID e SCHNITMAN, 2012).

Uma importante classe de identificação de sistemas caixa preta é o modelo autoregressivo com entradas exógenas (ARX do inglês *autoregressive model with exogenous input*) (SÖDERSTRÖM e STOICA, 1989; LJUNG, 1999). Este modelo constitui uma poderosa ferramenta no campo da identificação de sistemas dinâmicos lineares, podendo em muitos casos ser usado na modelagem de sistemas fracamente não-lineares, possuindo aplicações em diversas áreas, como simulação, análise, controle e monitoramento (MAHFOUF, KANDIAH e LINKENS, 2002; KARNY e PAVELKOVA, 2007).

Embora em alguns casos aproximações lineares sejam suficientes para representar aplicações práticas, os sistemas dinâmicos encontrados no mundo real são, em última análise, não-lineares (AGUIRRE, 2000). Modelos não-lineares como redes neurais artificiais (RNAs) (HAYKIN, 1998), modelos não-lineares autoregressivos com entradas exógenas (NARX) (LJUNG, 2001) e de Hammerstein-Wiener (NELLES, 2001; Z. ZHANG, G. LIU E F. LIU, 2001), baseados em RNAs e em *wavelet networks* (também chamada de *wavenet*) (ZHANG e BENVENISTE, 1992; ZHANG, 1997), têm recebido muita atenção devido à aprendizagem de mapeamentos complexos a partir de um conjunto de dados medidos. Estes modelos são estruturas flexíveis que, basicamente, durante a etapa de treinamento, ajustam seus parâmetros internos de acordo com os dados observados na entrada e/ou saída, e possuem a habilidade de reproduzir diferentes regimes dinâmicos para diferentes pontos de operação para os quais tenham sido treinados.

Neste trabalho, são aplicados métodos de identificação de sistemas dinâmicos para obter estruturas capazes de inferir posição e carga de haste polida de bombeio mecânico (BM) de óleo a partir de variável elétrica de motor. Mais especificamente, posição e carga dinâmica na haste polida de BM constituem as saídas dos sistemas identificados; e as variáveis elétricas de motor de indução trifásico: tensão AC, corrente de torque e corrente estatórica, são as candidatas à entrada do sistema.

O capítulo 2 desta dissertação aborda o ciclo de identificação de sistemas dinâmicos, onde, dentre outros, são vistos o modelo linear ARX, modelo não-linear ARX (NARX) e o modelo de Hammerstein-Wiener. A função não-linear usada no modelo NARX e de Hammerstein-Wiener, a *wavelet network*, é vista no capítulo 3. O capítulo 4 trata do bombeio mecânico de petróleo por hastes, da carta dinamométrica e dos padrões de carta tratados de modo experimental nesta dissertação. O capítulo 5 evidencia o conjunto experimental, e partes do ciclo de identificação, as quais vão do planejamento de experimento até a seleção e tratamento dos sinais a serem usados na identificação. No capítulo 6, os sistemas que envolvem posição e carga dinâmica em haste de bombeio são identificados, sendo apresentados os resultados obtidos e realizadas as discussões. Por fim, no capítulo 7 é realizada a conclusão e recomendações para trabalhos futuros.

1.1 JUSTIFICATIVA

De acordo com Sjöberg et al. (1995) estruturas não-lineares caixa-preta para identificação de sistemas dinâmicos são capazes de descrever virtualmente qualquer dinâmica não-linear. Deste modo, pode-se vislumbrar que seja possível substituir os sensores físicos de posição e carga usados na haste polida de bombeio mecânico de óleo, por sensores virtuais que possam ser integrados a sistemas microprocessados existentes no controle do BM, como o inversor de frequência.

Existem inúmeras desvantagens no uso de sensores físicos de posição e carga, como o custo com aquisição, calibração e manutenção, já que as indústrias do ramo petrolífero possuem centenas de poços. Assim a substituição do instrumento físico por um virtual é uma alternativa adequada se o ajuste ou treinamento dos modelos for possível.

1.2 OBJETIVO GERAL

Inferir posição e carga dinâmica de haste polida de BM a partir de variável elétrica de motor de indução trifásico.

1.3 OBJETIVO ESPECÍFICO

- identificar modelo(s) capaz(es) de inferir, para determinadas condições operacionais do sistema de bombeio, a posição dinâmica da haste polida a partir de variável elétrica de motor;
- identificar modelo(s) capaz(es) de inferir, para determinadas condições operacionais do sistema de bombeio, a carga dinâmica suportada pela haste polida a partir de variável elétrica de motor;
- obter a carta dinamométrica de superfície (CDS) para determinadas condições de bombeio mecânico.

2 IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS

A identificação de sistemas, também chamada de modelagem empírica, é uma área da ciência que trata da obtenção de modelos matemáticos a partir de dados experimentais. Ljung (1997) define a identificação de sistemas como “a arte e a metodologia de construir modelos matemáticos de sistemas dinâmicos, baseando-se nos dados de entrada e saída do sistema”.

Dentre as motivações na obtenção de modelos matemáticos, destacam-se:

- a predição de comportamentos futuros baseado em observações passadas;
- a estimação das variáveis de estado que não podem ser facilmente medidas em tempo real com base em medições disponíveis para, por exemplo, fornecer informações do processo em tempo real;
- o uso dos modelos no controle, supervisão, otimização, detecção de falhas e diagnóstico de componentes de processos;
- a simulação de situações e cenários, possibilitando conhecer (analisar) o comportamento do sistema para determinadas faixas de operações.

Um dos pioneiros na criação e uso de técnicas de identificação de sistemas, que se tem registro, foi o cientista matemático, alemão, Johann Carl Friedrich Gauss (30 de Abril 1777 – 23 de Fevereiro 1855) (BÜHLER, 1981). Gauss desenvolveu um método denominado mínimos quadrados, que até hoje é usado para descrever com precisão a trajetória de corpos celestes (BRETSCHER, 1995). Dentre as principais motivações no uso de técnicas de identificação de sistemas, tem-se que:

- muitas vezes a construção de modelos matemáticos baseados nas leis da física pode ser inexecutável com os recursos e tempo disponíveis, ou por causa da complexidade dos fenômenos envolvidos (LJUNG, 1999);
- todos os sistemas existentes são em última análise não-lineares (AGUIRRE, 2000), e sistemas fortemente não-lineares são complexos de serem modelados fenomenologicamente (NELLES, 2001);
- a construção de modelos fenomenológicos podem consumir muito tempo e dinheiro, devido a complexidade (CAJUEIRO, KALID E SCHNITMAN, 2011 (A));

- modelos identificados podem ser obtidos em menos tempo com menos esforço em comparação com a modelagem teórica (ISERMANN E MÜNCHHOF, 2010);
- métodos de identificação são independentes do sistema investigado e podem, assim, ser aplicado a muitos sistemas diferentes (NELLES, 2001).

As técnicas empregadas na obtenção de modelos matemáticos são divididas em três grupos, os quais são:

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

Na identificação caixa-branca (também conhecida como modelagem pela física ou natureza do processo, ou ainda modelagem fenomenológica ou conceitual) os parâmetros do sistema e as leis da natureza que regem comportamento do sistema são bem conhecidos (GARCIA, 2005).

A modelagem caixa-cinza representa o compromisso ou a combinação entre a caixa-branca e a caixa-preta (NELLES, 2001), e é subdividida em dois diferentes tipos (JUDITSKY et al., 1995):

- modelagem física – alguns parâmetros são estimados dos dados, mas a estrutura do modelo é construída baseada nos aspectos físicos que regem o processo.
- modelagem semi-física – utiliza conhecimentos da física do processo para sugerir certas não-linearidades. Estas não-linearidades são então usadas na modelagem caixa-preta.

Na identificação caixa-preta, nenhum conhecimento sobre a dinâmica que rege o comportamento do processo se faz necessário para a modelagem do sistema (LJUNG, 2001). O sucesso da identificação de um sistema por um método tipo caixa-preta, seja ele linear ou não-linear, dependerá da escolha da estrutura do método a ser utilizado (LJUNG, 1995). De acordo com Sjöberg et al. (1995) estruturas não-lineares caixa-preta para identificação de sistemas dinâmicos são capazes de descrever virtualmente qualquer dinâmica não-linear.

Esta pesquisa tem foco na identificação de sistemas caixa-preta a batelada, cujo esquema geral de identificação é mostrado na Figura 2.1. Neste tipo de identificação, os dados de entrada e saída do sistema são amostrados e armazenados. Posteriormente, estes dados amostrados passam por várias etapas (chamadas de ciclo de identificação), até se obter o modelo desejado.

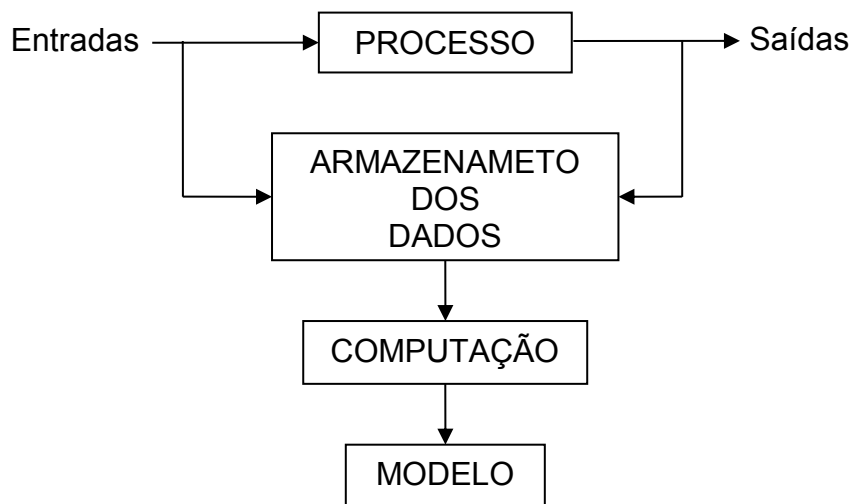


Figura 2.1: Identificação caixa preta a batelada de sistemas dinâmicos.

Na Figura 2.1, o bloco denominado “computação” abrange da subseção 2.1.3 a subseção 2.1.9, e refere-se a etapas do ciclo de identificação de sistemas, o qual é descrito na próxima seção.

2.1 O CICLO DE IDENTIFICAÇÃO DE SISTEMAS

De modo geral, a metodologia para identificação de sistemas consiste na aplicação das etapas mostradas na Figura 2.2 (SÖDERSTRÖM E STOICA, 1989; LJUNG, 1999; AGUIRRE, 2000); onde, cada um dos blocos destas podem exigir inúmeras tomadas de decisão, aliadas ao conhecimento *a priori* relacionado à escolha, tratamento dos dados e validação, sempre que necessário. Como exemplo, referindo-se a escolha do sinal de entrada para a identificação de sistemas, os seguintes questionamentos são relevantes para tomada de decisão (SÖDERSTRÖM E STOICA, 1989; LJUNG E GLAD, 1994):

- Qual sinal deve ser escolhido como entrada?
- O sinal escolhido excita a dinâmica do sistema?
- Que taxa de amostragem deve ser usada?

- Que quantidade de dados deve ser amostrada?
- Os dados amostrados precisam ser filtrados?
- São todos os dados confiáveis?
- Os dados precisam ser reamostrados?

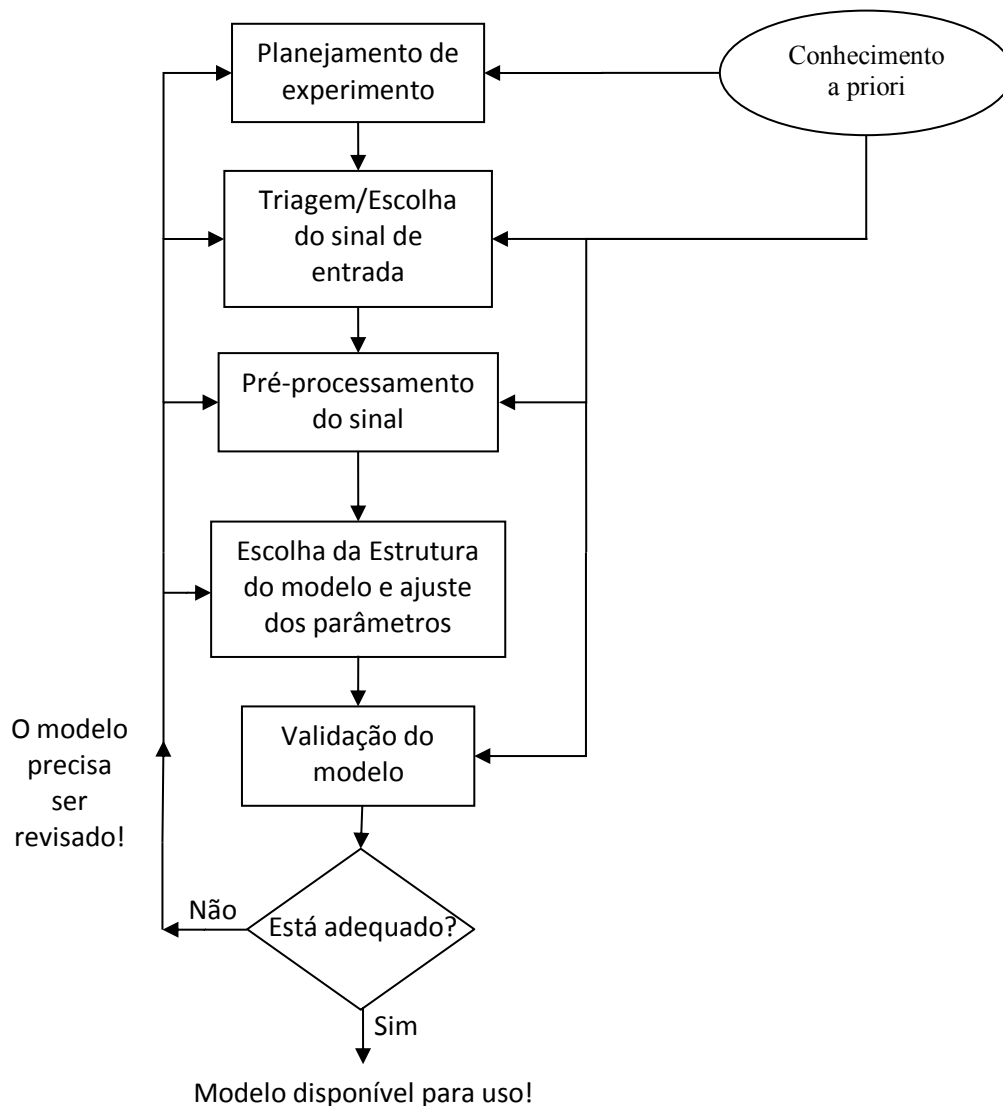


Figura 2.2: O ciclo de identificação de sistemas

Referindo-se ao conhecimento *a priori* mostrado na Figura 2.2, ressalta-se que ele não está relacionado a aspectos fenomenológicos que venham a modificar a forma da estrutura caixa-preta, mas a um conhecimento mínimo que auxilie na escolha do sinal de entrada, na escolha do tempo de amostragem, no pré-processamento dos sinais amostrados e na validação da estrutura.

Outro aspecto que vale ressaltar é que não existe um roteiro padrão para se obter sucesso na identificação de sistemas. Na prática, alguns dos procedimentos descritos na Figura 2.2 podem não ocorrer na ordem descrita.

Nas próximas subseções deste capítulo são vistos os conceitos abordados na metodologia geral de identificação (Figura 2.2). Tal metodologia serve como base das aplicações realizadas nos capítulos 5 e 6.

2.1.1 Planejamento de experimento para identificação de sistemas

Para que a identificação caixa-preta de sistemas tenha uma maior probabilidade de ser bem sucedida, o experimento deve ser planejado. Em suma, o planejamento do experimento visa definir quais dados, em que quantidade e em que condições devem ser amostrados durante a execução do experimento (LEONTARITIS E BILLINGS, 1987). Esta é uma das etapas mais importantes na identificação caixa-preta de sistemas, pois a qualidade da identificação não será superior à qualidade dos dados amostrados (LJUNG, 1999).

A seguir é dada uma breve descrição do planejamento do experimento adotado neste trabalho para a identificação de sistemas dinâmicos. Para uma abordagem do ponto de vista metodológico do planejamento de experimento recomenda-se a leitura do artigo de Coleman e Montgomery (1993) e do livro de Montgomery (1976). Para uma abordagem do planejamento de experimento para a indústria do ponto de vista estatístico, recomenda-se a leitura do livro de Box, Hunter e G. Hunter (2005).

A. Caracterização do experimento

O foco desta etapa é tornar claro o objetivo e propósito do experimento. Para este trabalho o objetivo do experimento é a amostragem de sinais para serem usados na identificação de sistemas dinâmicos para a geração de carta dinamométrica de superfície (CDS).

B. Definição das variáveis a serem amostradas

Esta etapa se baseia em *conhecimento a priori* sobre o processo e na experimentação, como descreve Nelles (2001, pg. 8). O *conhecimento a priori* não

está relacionado ao conhecimento fenomenológico completo sobre o sistema, pois se fosse este o caso, a aplicação de técnicas de identificação não teria sentido, e sim com conhecimentos que permitam que o usuário tenha o discernimento de escolher quais e como devem ser coletadas as variáveis candidatas à entrada e de saída do sistema a ser identificado.

Para o caso, em que durante o experimento pode-se manipular diretamente o sinal de entrada do sistema ($u(k)$), espera-se que $u(k)$ tenha energia e espectro de frequência suficiente para excitar as características dinâmicas do processo em uma ampla faixa de operação, a fim de que tais características sejam detectadas na saída do sistema ($y(k)$). Os livros de Ljung e Glad (1994) e Leontaritis e Billings (1987) descrevem os tipos de sinais mais comumente usados como entrada para a identificação de sistemas, assim como descreve as suas vantagens e desvantagens.

Em aplicações cujo foco é usar uma variável naturalmente existente no processo, é essencial que a variável a ser escolhida possua alguma relação com o sinal de saída do sistema, a fim de a modelagem faça sentido. Para a situação cujos relacionamentos entre as variáveis não são bem conhecidos, torna-se essencial que sejam amostradas tantas candidatas a entrada quanto possível, para que posteriormente através do uso de ferramentas matemáticas, na etapa triagem/escolha do sinal de entrada, seja possível escolher o sinal (ou os sinais) de entrada que possua uma correlação mais forte com o sinal de saída do sistema.

C. Definição do Período de Amostragem

O teorema da amostragem de Shannon oferece orientações importantes na escolha da frequência de amostragem (HAYKIN E VAN, 2001). De acordo com o teorema de Shannon, qualquer sinal de banda limitada com conteúdo de frequência $\omega \in [-\omega_B, \omega_B]$, amostrado com frequência de amostragem $\omega_s > 2\omega_B$ pode ser reconstruído sem perda de informação.

Na prática, de acordo com Ljung e Glad (1994) uma regra muito importante é escolher uma frequência de amostragem cerca de 10 vezes maior do que a máxima frequência de interesse contida no sinal. Ainda de acordo com os autores, é melhor amostrar um sinal com uma frequência demasiadamente alta (superamostrar), do que amostrá-lo com uma frequência demasiadamente baixa (subamostrar), pois sinais superamostrados podem ser decimados (reamostrados) e/ou filtrados.

Para o caso em que os sinais são subamostrados, a reconstrução destes não corresponderá ao sinal original. Isso faz com que o modelo identificado a partir de tais amostras seja incapaz de reproduzir as características estáticas e dinâmicas do sistema real (VERHAEGEN E VERDULT, 2007). O desejável, se possível, de acordo com Aguirre (2000, pg. 369), é amostrar os dados com uma frequência demasiadamente alta para que por meio de um método que aplica as funções de covariância linear e não-linear seja descoberta uma taxa de amostragem e/ou decimação adequada, como será visto na seção 2.1.3.

D. Definição das condições operacionais para coleta de dados

A identificação em processos cuja dinâmica é lenta, ou processos que se comportam de modos diferentes a depender das condições operacionais, exige que no planejamento fique bastante claro quais condições operacionais se deseja que sejam exploradas a fim de que elas fiquem registradas nos dados, pois o modelo identificado não será capaz de reproduzir características para as quais não tenha sido treinado (AGUIRRE, 2000). Caso o sistema não permita a manipulação direta do sinal de entrada, a fim de se excitar a planta, pode-se escolher variáveis independentes e que influenciem diretamente os dados que serão amostrados a fim de que as características do sistema fiquem registradas nos dados. Desta forma, usando-se estruturas de identificação não-lineares, pode-se, ao menos a princípio, ajustar um modelo capaz de reproduzir as características do sistema identificado em diferentes pontos de operação. Por outro lado, caso o sistema seja excitado em torno de um ponto de operação, é possível que um modelo linear seja capaz de se ajustar aos dados (LJUNG, 2001).

2.1.2 Triagem/Escolha do Sinal de Entrada

Durante o planejamento do experimento escolhem-se as variáveis candidatas a serem entradas no modelo de identificação. Já nesta etapa são aplicadas ferramentas matemáticas a fim de se escolher a variável mais adequada, das previamente amostras, a serem usadas na identificação. Neste sentido, *funções de correlação cruzada* (FCC) entre os sinais candidatos à entrada e entre os sinais de entrada e saída ajudam na escolha das variáveis a serem usadas como entrada na identificação (SÖDERSTRÖM E STOICA, 1989). A FCC permite medir a força de

relacionamento linear entre dois sinais.

Para funções contínuas a FCC pode ser estimada do seguinte modo:

$$r_{uy}(\tau) = \frac{1}{2T} \int_{-T}^T u(t)y(t + \tau)dt, \quad (2.1)$$

onde T é o período de observação. E para a forma discreta:

$$r_{uy}(\tau) = \frac{1}{N} \sum_{k=1}^N u(k)y(k + \tau) \quad (2.2)$$

onde N é o número de amostras, u e y correspondem, respectivamente, aos sinais de entrada e saída com média nula, e τ corresponde ao número de atrasos (ISERMANN E MÜNCHHOF, 2010). Uma propriedade importante da função de correlação cruzada diz que:

$$r_{uy}(\tau) = \frac{1}{N} \sum_{k=1}^N u(k)y(k + \tau) = r_{yu}(\tau) = \frac{1}{N} \sum_{k=1}^N y(k)u(k + \tau).$$

Outra forma de se calcular a FCC consiste em transformar os sinais para o domínio da frequência, através da transformada discreta de *Fourier (DFT)*; em seguida efetuar a multiplicação; e após a multiplicação, aplicar a *transformada inversa discreta de Fourier*, como mostra a equação 2.3:

$$r_{uy} = \frac{1}{N} DFT^{-1}[DFT\{u(-k)\}DFT\{y(k)\}] \quad (2.3)$$

onde DFT é a *transformada discreta de Fourier (no inglês Discret Fourirer Transform – DFT)* e DFT^{-1} representa a *transformada inversa discreta de Fourier*; e $u(-k)$ é o sinal de entrada refletido sobre o domínio do tempo. Na prática, especialmente quando o número de amostras é grande, a equação (2.3) é mais facilmente aplicada por meio da transformada rápida de Fourier (FFT), como mostra o capítulo 3 do livro de Ifeachor e Jervis (2002). Para detalhes sobre a aplicação da DFT recomenda-se a leitura do livro de Ifeachor e Jervis (2002, pg. 111).

Para a FCC, tem-se que quanto mais próximo de 1 ou -1 o valor da correlação estiver, significa que mais forte é o relacionamento linear entre as variáveis. Do mesmo modo, quanto mais próximo de 0 (zero) o resultado da FCC, menor será a relação entre as variáveis. O resultado da FCC é comumente tomado em módulo, pois o sinal negativo para a FCC indica que variáveis correlacionadas possuem relação inversa.

Para mais detalhes sobre funções de correlação cruzada recomenda-se a leitura dos livros de Isermann e Münchhof (2010) e Ifeachor e Jervis (2002).

2.1.3 Pré-processamento dos dados

O pré-processamento dos dados refere-se ao tratamento do sinal amostrado. Nesta etapa, utilizam-se técnicas de processamento digital de sinais a fim de tornar os sinais adequados para a identificação. É nesta etapa que, se necessários, os sinais amostrados são tratados (filtrados, decimados, etc).

A fim de se manter as relações lineares entre os dados de entrada e saída de um sistema, faz-se necessário que ambas as entradas e saídas sejam filtradas através de um mesmo filtro, conforme apresentado nas equações (2.4) e (2.5):

$$u_f(z) = h(z)u(z) \quad (2.4)$$

$$y_f(z) = h(z)y(z) \quad (2.5)$$

onde $h(z)$ é a função de transferência do filtro (IFEACHOR E JERVIS, 2002). Vale ressaltar que tanto a FFT quanto a *transformada wavelet* podem ser aplicadas a fim de (baseado em conhecimento a priori) se tentar descobrir a região de frequência ocupada pelo ruído (DAUBECHIES, 1992), no objetivo de facilitar o projeto e aplicação de filtros.

No que diz respeito à taxa de decimação (Δ , onde $\Delta \in \mathbb{N}$) a ser aplicada a um sinal superamostrado, de acordo com Aguirre (2000), a análise do grau de redundância entre amostras adjacentes deste sinal oferece uma boa estimativa para encontrar o valor de Δ . Em suma, o método descrito por Aguirre (2000) é dado como se segue:

1. Determina-se as funções de autocovariância linear e não-linear do sinal superamostrado $y(k)$:

$$r_y(\tau) = E[(y(k) - \bar{y}(k))(y(k - \tau) - \bar{y}(k))] \quad (2.6)$$

$$r_{y^2}(\tau) = E[(y^2(k) - \overline{y^2}(k))(y^2(k - \tau) - \overline{y^2}(k))] \quad (2.7)$$

2. Em seguida, determinam-se os primeiros pontos de mínimo de cada uma das funções acima, os quais são: $\varrho_{y=\min_1}(r_y(\tau))$ e $\varrho_{y^2=\min_1}(r_{y^2}(\tau))$, sendo que o

- índice ρ_1 denota o primeiro ponto de mínimo;
3. Escolhe-se o menor dentre os mínimos selecionados acima, ou seja, $\rho = \min [\rho_y, \rho_{y^2}']$, onde ρ é medido em número de atrasos;
 4. Por fim, determina-se a faixa de taxas de amostragem $\rho/20 < \Delta < \rho/10$.

Caso o período de amostragem seja muito maior do que o necessário, uma alternativa adequada, se possível, é refazer o experimento (LJUNG, 1999).

O pré-processamento dos dados, não apenas se refere a resolver problemas de superamostragem ou de subamostragem, mas também se refere a identificar e eliminar ruídos, problemas de medição ou picos de sinal (*outliers*), distúrbios de baixa frequência (como desvios de sinal, no inglês: *drift*).

Os livros de Ljung (1998, pg. 458) e Isermann e Münchhof (2010, pg. 588) trazem uma abordagem detalhada sobre o pré-processamento de dados para a identificação. Já o livro de Ifeachor (2002) traz uma abordagem prática do uso das técnicas de processamento digital de sinais.

2.1.4 Determinação/Escolha da Estrutura Linear

A escolha do tipo de modelo, se linear ou não linear, e conseqüentemente da sua estrutura a ser utilizada na identificação é uma das tarefas mais difíceis de serem feitas, haja vista que diferentes abordagens de identificação de sistemas podem ser usadas na tentativa de se obter um modelo empírico. Nesta seção serão abordadas estruturas de modelos lineares.

Uma família geral de estrutura de modelo linear largamente utilizado na identificação de sistemas pode ser escrita pela seguinte equação geral (LJUNG, 1999):

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}e(k) \quad (2.8)$$

onde $A(q), B(q), F(q), C(q)$ e $D(q)$ são polinômios de q , operador de atraso, que contém os parâmetros estimados (ou que se quer estimar) a partir dos dados e capazes de representar a dinâmica de sistemas lineares; $u(k)$ e $y(k)$ são respectivamente os sinais de entrada e saída amostrados no instante k , e $e(k)$ um

ruído branco. Isolando $y(k)$ na equação (2.8) se obtém a saída do modelo

$$y(k) = \frac{B(q)}{F(q)A(q)}u(k) + \frac{C(q)}{D(q).A(q)}e(k) \quad (2.9)$$

Para o caso em que existe tempo morto (atraso de tempo, aqui definido como n_k) entre o sinal de entrada $u(k)$ e saída $y(k)$ do sistema, pode-se escrever o polinômio $B(q)$ da seguinte modo:

$$B(q) = b_{nk}q^{-nk} + b_{nk+1}q^{-nk-1} + \dots + b_{nk+nb-1}q^{-nk-nb+1} = b_{nk}\bar{B}(q)$$

Para $A(q), C(q), D(q)$ e $F(q)$, tem-se:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na}$$

$$C(q) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc}$$

$$D(q) = 1 + d_1q^{-1} + \dots + d_{nd}q^{-nd}$$

$$F(q) = 1 + f_1q^{-1} + \dots + f_{nf}q^{-nf}$$

onde q^{-1} é o operador de atraso, ex.: $q^{-1}x(k) = x(k-1)$; e na, nb, nc, nd e nf correspondem à ordem dos polinômios.

A partir da equação (2.9) é possível obter diversos modelos lineares, como mostra o Quadro 2.1 (Ljung, 1999).

Quadro 2.1: Modelos Lineares Típicos

Estruturas do Modelo	Equações do Modelo
AR - Autoregressivo	$y(k) = (1/D(q)).e(k)$
ARX – AR com Entradas Exógenas	$y(k) = (B(q)/A(q)).u(k) + (1/A(q)).e(k)$
ARMAX – ARX com Média Móvel	$y(k) = (B(q)/A(q)).u(k) + (C(q)/A(q)).e(k)$
OE – Desvio na Saída	$y(k) = (B(q)/F(q)).u(k) + e(k)$
BJ – Box-Jenkins	$y(k) = (B(q)/F(q)).u(k) + (C(q)/A(q)).e(k)$
FIR – Resposta ao Impulso Finita	$y(k) = B(q).u(k) + e(k)$

Na prática, a estrutura do modelo a ser testada na identificação em geral não é conhecida *a priori* e deve ser determinada também a partir dos dados. No caso, para se estimar os modelos descritos no Quadro 2.1 faz-se necessário que suas ordens e atrasos também sejam obtidos.

Devido a grande eficácia do modelo ARX na identificação de sistemas dinâmicos lineares e em muitos casos de sistemas não-lineares, o mesmo foi usado nesta dissertação. Tal escolha foi motivada em análises preliminares devido ao fato de que os resultados mais significativos tenham sido obtidos por meio do modelo ARX, se comparado aos resultados obtidos pelos demais modelos citados no Quadro 2.1. Por isso, referindo-se à identificação de sistemas dinâmicos lineares, apenas o modelo ARX será usado nesta dissertação.

Para maiores detalhes sobre o modelo ARX considere o disposto na subseção 2.1.4.1. Para maiores detalhes sobre os demais modelos descritos no Quadro 2.1, recomenda-se a leitura dos livros de Söderström e Stoica (1989), Ljung (1999), Aguirre (2000) e Isermann e Münchhof (2010); e do artigo de Ljung (2001).

2.1.4.1 Modelo ARX

O modelo ARX pode ser visto tanto como um modelo AR estendido, quanto como um caso particular do modelo ARMAX (ver Quadro 2.1). Ele pode ser representado como mostra Figura 2.3:




Figura 2.3: Estrutura do modelo ARX

onde obtendo-se a expressão a partir da Figura 2.5, tem-se:

$$A(q)y(k) = B(q)u(k) + e(k),$$

e isolando $y(k)$ na expressão anterior, se obtém:

$$y(k) = (B(q)/A(q)).u(k) + (1/A(q)).e(k) \quad (2.10)$$

Normalmente, em se tratando de identificação de sistemas dinâmicos, modelos mais simples, como o modelo ARX, são primeiramente usados antes de se tentar utilizar estruturas mais complexas; apenas caso o resultado obtido não seja satisfatório é que se opta por usar estruturas mais complexas, como as não-lineares.

O modelo ARX, dado em (2.10), pode ser reescrito na forma da equação das diferenças:

$$y(k) = -a_1 y(k-1) - \dots - a_{na} y(k-na) + b_1 u(k-nk) + \dots + b_{nb} u(k-nk-nb+1) + e(k) \quad (2.11)$$

onde na é visto como o número de auto-regressores, nb o número de regressores exógenos.

Uma das vantagens de se utilizar o modelo linear ARX é que seus parâmetros são facilmente estimados utilizando-se o algoritmo dos mínimos quadrados. Tal método é descrito na seção 2.1.7.1.

2.1.5 Determinação/Escolha da Estrutura Não-Linear

Embora em alguns casos aproximações lineares (como as descritas na seção 2.1.4) sejam suficientes para representar aplicações práticas, os sistemas dinâmicos encontrados no mundo real são, em última análise, não-lineares (AGUIRRE, 2000). Para sistemas que operam em larga faixa de operação ou sistemas altamente não-lineares, modelos lineares não são suficientes (LJUNG, 2001). Modelos não-lineares como redes neurais artificiais (RNAs) (HAYKIN, 1998), modelos não-lineares autoregressivos com entradas exógenas (NARX) e de Hammerstein-Wiener (JUDITSKY et al., 1995; NELLES, 2001), baseados em RNAs, ou em *wavelet networks* (wavenet) (ZHANG E BENVENISTE, 1992; ZHANG, 1997), têm recebido muita atenção nas três últimas décadas (MASOUM; JAMALI E GHAFARZADEH, 2010; EL-ASHI, DHAOUADI E LANDOLSI, 2011; RAJAMANI, DEY E CHAKRAVORTI, 2011; ZHANG, GAO E LI, 2012; CAJUEIRO, KALID E LEIZER, 2012), devido à aprendizagem de mapeamentos complexos a partir de um conjunto de dados experimentais. Estes modelos são estruturas flexíveis que basicamente durante a etapa de treinamento ajustam seus parâmetros internos de acordo com os dados observados na entrada e/ou saída, e possuem a habilidade de reproduzir

diferentes regimes dinâmicos para diferentes pontos de operação para os quais sejam treinados.

Considere o problema de identificação caixa-preta a seguir:

$$y(k) = f(\Phi(k)) + \varepsilon \quad (2.12)$$

onde $\Phi(k)$ representa os dados de entrada para estimação da função f ; e $\varepsilon(k) = y(k) - \hat{y}(k)$ o desvio de modelagem (resíduo). O objetivo básico do problema de identificação dado pela equação (2.12) é determinar uma função f de modo que:

$$\sum_{k=0}^N \|y(k) - f(\Phi(k))\|^2 \text{ seja mínimo} \quad (2.13)$$

em que a norma e modo de achar o mínimo podem variar, mas o conceito básico é descrito na equação (2.13).

Diferentes funções podem ser usadas em f a fim de realizar o mapeamento não-linear, dentre as quais destacam-se:

- as redes neurais artificiais (RNAs) (HAYKIN, 1998);
- a lógica *fuzzy* (NELLES, 2001);
- e a *wavelet network* (ZHANG e BENVENISTE, 1992, ZHANG, 1997).

Pode-se observar acima que o problema da identificação caixa-preta de sistemas dinâmicos consiste basicamente em selecionar o vetor de entrada a ser usado no mapeamento não-linear entre as entradas e saídas, e o tipo de estrutura não-linear a realizar o mapeamento.

Nesta dissertação a função *wavelet network*, a qual será vista em detalhes no capítulo 3, foi escolhida para ser a função f dos modelos não-lineares usados neste trabalho, os quais são: modelo NARX e de Hammerstein-Wiener.

2.1.5.1 Modelo NARX

O modelo polinomial de Kolmogorov-Gabor, representa o modelo não-linear auto-regressivo com entradas exógenas (NARX) (NELLES, 2001). Este modelo é um subsistema do modelo NARMAX.

Partindo da forma da equação compacta do modelo linear ARX (a qual será tratada em detalhes na seção 2.1.8.1)

$$\hat{y}(k) = x(k)^T \theta \quad (2.14)$$

onde $x(k)$ é o vetor de regressores (memória do modelo) dado em (2.15), e θ é o vetor de coeficientes dado em (2.16),

$$x(k) = [y(k-1), \dots, y(k-n_a), \\ u(k-n_k), \dots, u(k-n_k-n_b+1)]^T \quad (2.15)$$

$$\theta = [-a_1, \dots, -a_{n_a}, b_1, \dots, b_{n_b}]^T \quad (2.16)$$

e \hat{y} é a saída obtida ao multiplicar os coeficientes pelos seus respectivos regressores. Ao invés de uma soma ponderada que representa o mapeamento linear, como é o caso do modelo ARX, o modelo não-linear ARX (NARX) usa um mapeamento não-linear entre as entradas e as saídas:

$$\hat{y}(k) = f(x(k)) \quad (2.17)$$

onde $x(k)$ é o vetor de regressores dado pela equação 2.15, e f é uma função não-linear. A Figura 2.4 mostra a estrutura geral do modelo NARX.




Figura 2.4: Estrutura geral do modelo não-linear ARX (NARX).

Quando o modelo NARX é usado para controle, ou quando a função f é uma rede neural ou *wavelet network*, pode-se adicionar a forma geral da equação (2.17) uma função afim (ZHANG, 1993). Isto resulta em um modelo NARX com uma estrutura série-paralela:

$$\hat{y}(k) = f(x(k)) + x(k)^T \theta + l \quad (2.18)$$

onde θ é o coeficiente da função afim e l é o offset de saída.

Dentre as vantagens no uso do modelo NARX, destaca-se: a possibilidade de identificar fenômenos não-lineares a um custo computacional muitas vezes comparável ao do modelo linear ARX (DE NICOLAO e TRECATE, 1998); a capacidade de poder exibir uma extensiva gama de comportamentos dinâmicos (NARENDRA e PARTHASARATHY, 1990; DOYLE, PEARSON e OGUNNAIKE, 2001); a possibilidade de poder usar diferentes funções não-lineares.

2.1.5.2 Modelo de Hammerstein-Wiener

O modelo de Hammerstein-Wiener é um modelo do tipo N-L-N (não linear - linear - não linear), no qual um bloco linear é envolvido entre dois blocos não-lineares. Este modelo é a combinação de duas estruturas: a estrutura de Hammerstein com a estrutura de Wiener (ZHU, 2002).

A estrutura de Hammerstein é um modelo N-L (não-linear - linear) que foi originado a partir da teoria das equações integrais não-lineares desenvolvidas a partir dos trabalhos de Hammerstein em 1930 (NARENDRA AND GALLMAN, 1966). Esta estrutura consiste de um bloco estático não-linear seguido por um bloco dinâmico linear. O modelo de Wiener se originou a partir da série de Wiener, desenvolvida pelo matemático Norbert Wiener em 1940. A estrutura do modelo de Wiener é o modelo de Hammerstein reverso, ou seja, o bloco dinâmico linear seguido pelo bloco estático não-linear (ZHU, 2002).

A combinação da estrutura de Hammerstein com a de Wiener, foi construída em analogia ao ambiente típico de controle de processo, onde o primeiro bloco não-linear (da sequencia N-L-N) representa a não-linearidade do atuador e o segundo bloco não-linear da sequencia representa a não-linearidade do processo. Segundo Zhu (2002), a combinação destes sistemas tem a capacidade matemática de representar de modo aproximado sistemas não-lineares melhor do que se os modelos não fossem combinados.

O diagrama de blocos dado na Figura 2.5 representa o modelo de Hammerstein-Wiener:




Figura 2.5: Modelo de Hammerstein-Wiener.

Do qual se obtém a as seguintes equações:

$$w_1(k) = f_1(u(k))$$

$$w(k) = G(q)w_1(k)$$

$$y(k) = f_2(w(k)) = f_2[G(q)f_1(u(k))] \quad (2.19)$$

onde f_1 e f_2 representam o modelo não-linear, nesta dissertação a *wavelet network*; $G(q) = B(q)/F(q)$ é uma função de transferência linear dinâmica, onde os polinômios $B(q)$ e $F(q)$ foram descritos para equação geral polinomial, a equação (2.8); $w_1(k)$ e $w(k)$ representam, respectivamente, a saída de f_1 e f_2 .

2.1.6 Determinação da ordem do modelo

A escolha da ordem do modelo caixa preta é em geral uma combinação de conhecimento (*a priori*) do sistema e *tentativa e erro* (NELLES, 2001). Em identificação de sistemas é comum que a ordem do modelo não seja conhecida *a priori* e precise ser determinada a partir dos dados amostrados do processo. Dois critérios estatísticos amplamente usados em identificação de sistemas são descritos na próxima subseção (LJUNG, 1999; NELLES, 2001; ISERMANN E MÜNCHHOF, 2010).

2.1.6.1 Função Penalidade e Desvio de Predição Final de Akaike

Em identificação de sistemas dinâmicos caixa-preta os seguintes passos são amplamente usados para a escolha da ordem do modelo:

1. Para sistemas lineares, sugerir a partir da análise de correlação cruzada (CRA) (seção 2.1.7) a ordem do modelo; e para sistemas não-lineares, sugerir aleatoriamente diversas ordens começando das ordens mais baixas para as mais altas;
2. em seguida, estimar os parâmetros para cada um dos modelos com base nas

- ordens sugeridas;
3. escolher a ordem adequada¹ para representar o sistema identificado, baseando-se nos resultados apresentados por um dos seguintes critérios: *Função Penalidade*, *Desvio de predição final de Akaike (FPE)* (AKAIKE, 1981), dentre outros;
 4. e por fim, escolher a ordem mais adequada a partir do resultado da validação cruzada e análise dos resíduos.

Os resultados da *função penalidade* e do FPE descrevem o quão longe o modelo estimado se encontra dos dados coletados. Estes critérios quantificam o comportamento da variância dos resíduos resultantes da inclusão do aumento do número de parâmetros e ao mesmo tempo penalizam a inclusão de cada termo. A ordem dinâmica “mais adequada” para representar o sistema a ser identificado é a que produz o menor valor de *função penalidade* ou menor valor do FPE, para a menor ordem possível. Uma ordem dinâmica maior do que a necessária irá aumentar de modo desnecessário a complexidade do modelo; por outro lado, subestimar a ordem dinâmica resultará em um modelo que não representa adequadamente o comportamento do sistema.

A **Função Penalidade** é definida pela seguinte equação,

$$V = \frac{1}{N} \sum_{k=1}^N \varepsilon(k|\theta_N) \varepsilon(k|\theta_N)^T, \quad (2.20)$$

onde N é o comprimento dos dados amostrados usados para estimação, $\varepsilon(k|\theta_N) = y(k) - \hat{y}(k|\theta_N)$ é o resíduo, θ_N representa os parâmetros estimados.

O **FPE** é um critério similar à função penalidade, e dado pela seguinte equação,

$$FPE = V \left[\frac{N + n_\theta}{N - n_\theta} \right] \quad (2.21)$$

onde V é a *Função Penalidade*, n_θ é o número de parâmetros estimados e N é o comprimento dos dados amostrados (AKAIKE, 1981).

¹ Como estes critérios são baseados em um número finito de resultados, não se pode garantir que a ordem apontada por eles seja a mais adequada para a representação do modelo identificado.

2.1.7 Estimação de Parâmetros

Após a definição da estrutura a ser usada na identificação, o próximo passo no ciclo de identificação de sistemas consiste em estimar os parâmetros do modelo. Um ponto crítico na estimação dos parâmetros do modelo é que estes sejam escolhidos de modo que o ajuste do modelo seja bom (SJÖBERG et al., 1995). Em outras palavras, espera-se que os parâmetros sejam obtidos de modo a minimizar a função penalidade (equação 2.20).

Neste trabalho tanto a estrutura linear ARX quanto os pesos da estrutura não-linear f (a *wavelet network*) são estimados basicamente pelo método dos mínimos quadrados, o qual é descrito na próxima subseção.

Devido à importância do estimador de não-linearidade f (a *wavelet network*) usado no modelo NARX, este é tratado no capítulo 3 desta dissertação.

2.1.7.1 Método dos Mínimos Quadrados

Supondo que um conjunto de sinais de entrada e saída tenham sido medidos e escritos como $\mathbf{u} = [u(1), u(2), \dots, u(N)]^T$, $\mathbf{y} = [y(1), y(2), \dots, y(N)]^T$; usando o modelo ARX, é possível obter a saída do modelo $\hat{y}(k)$ dado valores passados de entrada e saída:

$$\hat{y}(1) = -a_1 y(0) - \dots - a_{na} y(1-na) + b_1 u(1-nk) + \dots + b_{nb} u(2-nk-nb)$$

$$\hat{y}(2) = -a_1 y(1) - \dots - a_{na} y(2-na) + b_1 u(2-nk) + \dots + b_{nb} u(3-nk-nb)$$

:

$$\hat{y}(N) = -a_1 y(N-1) - \dots - a_{na} y(N-na) + b_1 u(N-nk) + \dots + b_{nb} u(N+1-nk-nb)$$

onde para $k \leq 0$ tem-se que $y(k) = 0$ e $u(k) = 0$. A fim de determinar os coeficientes a_n e b_n , pode-se reescrever o modelo ARX acima na forma de regressão linear:

$$\hat{\mathbf{Y}} = \mathbf{X}^T \boldsymbol{\theta} \quad (2.22)$$

onde,

$$\hat{Y} = \begin{bmatrix} \hat{y}(1) \\ \hat{y}(2) \\ \vdots \\ \hat{y}(N) \end{bmatrix}$$

$$X = \begin{bmatrix} y(0) & \dots & y(1 - n_a) & u(1 - n_k) & \dots & u(2 - n_b - n_k) \\ y(1) & \dots & y(2 - n_a) & u(2 - n_k) & \dots & u(3 - n_b - n_k) \\ \vdots & & \vdots & \vdots & & \vdots \\ y(N - 1) & \dots & y(N - n_a) & u(N - n_k) & \dots & u(N + 1 - n_b - n_k) \end{bmatrix}$$

$$\theta^T = [-a_1, \dots, -a_{n_a}, b_1, \dots, b_{n_b}]$$

A matriz X é chamada matriz de regressores e cada coluna dessa matriz é formada por um regressor; o vetor θ é um vetor coluna e representa os coeficientes do modelo ARX. A fim de determinar θ , a função penalidade, equação (2.20), deve ser minimizada com respeito à θ :

$$\min_{\theta} V_N(\theta) = \frac{1}{N} \sum_{k=1}^N \|\varepsilon(k, \theta)\|^2 = \frac{1}{N} \varepsilon_N^T \varepsilon_N$$

onde,

$$\varepsilon(k, \theta) = y(k) - x(k)^T \theta$$

$$x(k) = [y(k - 1) \quad \dots \quad y(k - n_a) \quad u(k - n_k) \quad \dots \quad u(-n_b - n_k)]$$

$$\varepsilon_N = \begin{bmatrix} y(1) - x^T(1)\theta \\ y(2) - x^T(2)\theta \\ \vdots \\ y(N - 1) - x^T(N - 1)\theta \end{bmatrix}$$

Fazendo $\frac{\partial \varepsilon_N}{\partial \theta} = 0$, a fim de minimizar a função penalidade, tem-se:

$$\begin{aligned} \|\varepsilon\|^2 &= \varepsilon^T \varepsilon = (Y - X\theta)^T (Y - X\theta) \\ &= Y^T Y - Y^T X\theta - \theta^T X^T Y + \theta^T X^T X\theta \end{aligned}$$

$$\frac{\partial \varepsilon_N}{\partial \theta} = -2X^T Y + 2X^T X\theta = 0$$

$$X^T Y = X^T X\theta \quad (2.23)$$

$$\hat{\theta} = (X^T X)^{-1} X^T Y \quad (2.24)$$

onde a equação (2.23) é conhecida como *equação normal* e a matriz $(X^T X)^{-1} X^T$ na

equação (2.24) é chamada de matriz pseudo-inversa² (MOORE, 1920).

Devido à possibilidade de mau condicionamento numérico³ dada pela aplicação direta da *equação normal*, como é detalho no livro de Griva, Nash e Sofer (2009, capítulo 3 e Apêndice A.7.3), abordagens mais sofisticadas, como a *decomposição QR*, podem ser usadas com o objetivo de resolver o problema dos mínimos quadrados.

2.1.7.2 Decomposição QR

A decomposição *QR* (também chamada de fatorização *QR*) de uma matriz de regressores X é dada pela decomposição desta matriz como um produto de uma matriz ortogonal⁴ Q (ou seja, $Q^T Q = I$), $m \times n$, por uma matriz triangular superior R , $n \times n$

$$X = QR. \quad (2.25)$$

Sendo assim, de modo equivalente ao problema dos mínimos quadrados calculado na subseção anterior, equação (2.23), tem-se:

$$(QR)^T Y = (QR)^T QR\theta$$

$$R^T Q^T Y = R^T (Q^T Q) R\theta$$

$$R^T Q^T Y = R^T R\theta$$

$$(R^T)^{-1} R^T Q^T Y = (R^T)^{-1} R^T R\theta$$

$$Q^T Y = R\theta$$

onde fazendo $Q^T Y = \vartheta$, tem-se:

$$\vartheta = R\theta$$

onde ϑ é o vetor de parâmetros transformado e está relacionado com parâmetro original θ . Como R é uma matriz triangular, bastará usar substituições sucessivas para encontrar o valor de ϑ .

² O uso da matriz pseudo-inversa é comum no contexto dos mínimos quadrados, onde se tem que, em geral, o número de observações é maior do que o número de parâmetros.

³ Erros de arredondamento quando se recorre a um sistema computacional numérico no cálculo matricial (GRIVA, NASH E SOFER, 2009).

⁴ Matrizes ortogonais preservam a solução para um problema dos mínimos quadrados lineares, pois não alteram o comprimento euclidiano do vetor. A matriz Q possui colunas ortogonais.

A decomposição QR é comumente calculada pelo método modificado de Gram-Schmidt⁵ (HAN E NEUMANN, 2007). Este método é descrito no Capítulo 3 desta dissertação.

2.1.8 Validação do modelo

Como visto na Figura 2.2 (seção 2.1), após a escolha da estrutura do modelo e ajuste dos parâmetros, o mesmo precisa ser validado a fim de se certificar que o modelo é adequado para representar a dinâmica do sistema em estudo. Na prática, se alterna entre a estimativa e validação até encontrar o modelo mais simples que melhor satisfaz o propósito da identificação.

Os seguintes métodos são comumente usados na validação de modelos lineares estimados (LJUNG E HJALMARSSO, 1995; JUDITSKY et al., 1995):

- validação cruzada;
- análise de resíduos;
- mapa de pólos e zeros de modelos paramétricos lineares;
- resposta ao impulso e degrau.

Nas próximas subseções, apenas os dois primeiros casos serão abordados, pois de acordo com Ljung e Hjalmarsson (1995) tais métodos são os mais comumente usados para a validação.

2.1.8.1 Validação Cruzada

Na validação cruzada o desempenho do modelo identificado é avaliado para um conjunto de dados diferente daquele usado para a estimação dos parâmetros. Isto pode ser possível, por exemplo, dividindo-se o conjunto de dados em duas partes: os primeiros 2/3 do total do número de amostras é utilizado para a estimação de parâmetros, enquanto o 1/3 restante é usado para avaliar a qualidade do modelo (JUDITSKY et al., 1995).

A equação (2.26) mostra, em porcentagem, o quanto o modelo estimado se ajusta aos dados experimentais de validação:

⁵ A decomposição QR é uma interpretação matricial do método clássico de Gram-Schmidt. O método modificado de Gram-Schmidt supera a instabilidade numérica do método clássico (Han e Neumann, 2007).

$$ajuste = \left(1 - \frac{\sum_{k=1}^N |y_k - y_{S_k}|}{\sum_{k=1}^N |y_k - \bar{y}|} \right) \times 100, \quad (2.26)$$

onde y_k (y_1, \dots, y_N) é a saída medida, y_{S_k} (y_{S_1}, \dots, y_{S_N}) é a saída do modelo estimado, e \bar{y} é a média do vetor y_k . Para a equação (2.26) o valor de 100% corresponde a um ajuste perfeito.

2.1.8.2 Análise dos Resíduos

A parte dos dados de identificação que o modelo não consegue explicar é chamada de resíduo:

$$\varepsilon = y - \hat{y} \quad (2.27)$$

onde y é o vetor de saída medida do sistema, e \hat{y} é o vetor de saída simulada, o qual é obtido usando a sequência de dados de entrada contida no *conjunto de estimação* no modelo estimado. Caso o sinal usado como entrada para a obtenção de \hat{y} pertença ao conjunto de dados de validação (ou seja, dados diferentes dos usados para a estimação do modelo), então a equação (2.27) é chamada de equação do desvio de simulação. De acordo com Ljung e Hjalmarsson (1995), dois testes tem se mostrado simples e eficazes na análise dos resíduos: o teste de branqueamento⁶ e o teste de independência.

O teste de branqueamento diz que quanto mais decorrelacionado o resíduo estiver com ele mesmo, melhor será o modelo estimado:

$$r_\varepsilon(\tau) = \frac{1}{N} \sum_{t=1}^N \varepsilon(t) \varepsilon(t - \tau) \quad (2.28)$$

onde r_ε é o cálculo da função de autocorrelação entre os resíduos ε . O teste da independência diz que quanto mais decorrelacionado o sinal de entrada estiver dos resíduos, melhor será a qualidade do modelo estimado:

$$r_{\varepsilon u}(\tau) = \frac{1}{N} \sum_{t=1}^N \varepsilon(t) u(t - \tau) \quad (2.29)$$

⁶ O termo branqueamento ou brancura é usado em analogia ao funcionamento da luz branca, o qual diz que a mesma possui componentes em todo o espectro de frequência da luz visível.

onde r_{eu} representa o cálculo da função de correlação cruzada entre os resíduos e a entrada.

Estatisticamente, referindo-se a dados com distribuição Gaussiana, é conhecido que se a função de autocorrelação residual estiver dentro do intervalo de confiança de 3 desvios padrões (99%), diz-se que o modelo passou no teste do branqueamento (SÖDERSTRÖM e STOICA, 1989). De acordo com Söderström e Stoica (1989), a evidência de correlação fora deste intervalo pode ser uma indicação de que o modelo obtido não será capaz de descrever, de modo adequado, como parte do sinal de saída se relaciona com o sinal correspondente de entrada. Por outro lado, Ljung e Hjalmarsson (1995) mostram que embora os testes do branqueamento e da independência tenham sido construídos com base na estrutura probabilística, tais técnicas continuam fazendo sentido mesmo fora do contexto da teoria estatística, desde que a amplitude máxima dos resíduos ou a evidência de correlação entre a entrada e os resíduos, ou entre os resíduos, seja aceitável.

Por simplificar as análises de ajuste de modelos a dados experimentais, nesta dissertação será considerado somente o teste da validação cruzada, equação (2.26), tanto para a validação para o caso de identificação de sistemas dinâmicos lineares, quanto não-lineares.

2.2 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foi descrita uma metodologia usada na identificação de sistemas dinâmicos, denominada ciclo de identificação. Baseando-se em tal metodologia, métodos de identificação de sistemas lineares, não-lineares, técnicas de estimação e validação, foram tratadas. Tais abordagens teóricas unidas à função não-linear, a qual é dada no capítulo 3 (a *wavelet network*), serão aplicadas nos capítulos 5 e 6 ao problema de inferir posição e carga dinâmica a partir da medição de variáveis elétricas de motor, para determinar condições do BM.

3 WAVELET NETWORK

Nas próximas seções são abordados alguns conceitos sobre as funções wavelets. Tais conceitos permitirão compreender a *wavelet network* abordada na seção 4.7. A *wavelet network* ou *wavenet* é utilizada neste trabalho como função não-linear f do modelo NARX (equação 2.17), e em ambas as funções f_1 e f_2 do modelo de Hammerstein-Wiener (HW) (equação 2.19), os quais foram vistos na seção 2.1.5.

3.1 HISTÓRIA DAS WAVELETS

A primeira função wavelet foi desenvolvida em 1909, pelo matemático Húngaro Alfred Haar (HAAR, 1910). A wavelet de Haar forma bases ortonormais e possibilita representar de maneira aproximada qualquer função contínua $f(x)$ localizada no intervalo unitário $[0,1]$, com uma série de funções degraus (positivas e negativas), como mostra a Figura 3.1. Nota-se que a wavelet de Haar não é continuamente diferenciável. Tal propriedade faz desta uma função não suave, o que limita a sua aplicabilidade.

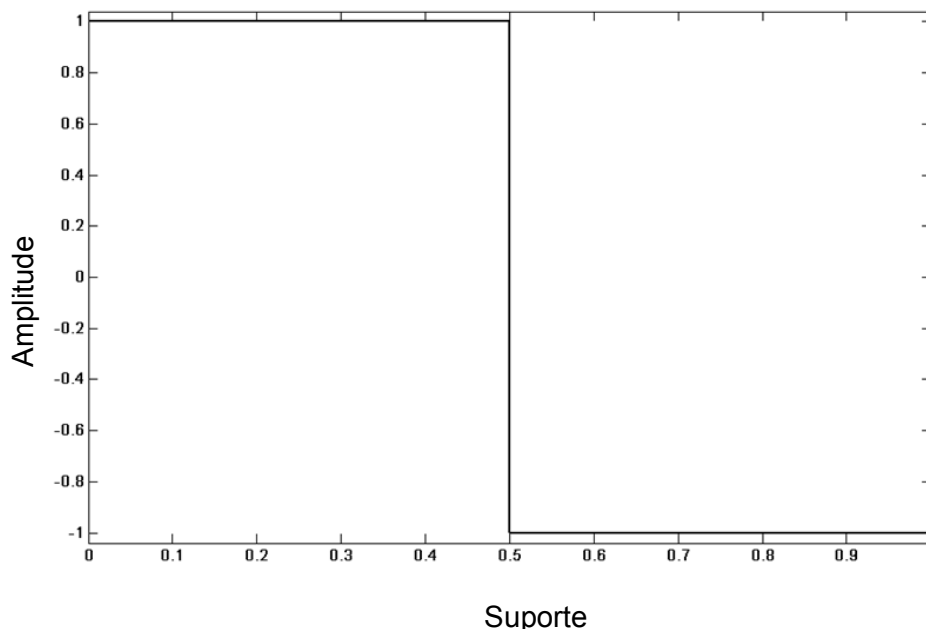


Figura 3.1: Função wavelet (ψ) de Haar.

Em 1930, Levy estudou o *movimento browniano*, um tipo de sinal aleatório, e acreditava que as funções de Haar eram superiores às de Fourier para estudar

detalhes complicados do movimento browniano. Posteriormente, entre 1975 e 1981, enquanto o geofísico Morlet estudava a transformada por janelas de Fourier para analisar sinais sísmicos, ele descobriu que variando a função janela era possível obter mais ou menos detalhes em tempo-frequência do sinal estudado (MORLET, 1983). Na prática, a wavelet de Morlet, pode ser vista como uma onda senoidal, modulada por uma função Gaussiana, como mostra a Figura 3.2.




Figura 3.2: Função wavelet (ψ) de Morlet.

Vale ressaltar que o termo wavelet foi criado por Morlet, no entanto a função criada por Haar é a primeira função wavelet construída. Em 1984, Morlet e um físico chamado Grossman descobriram que não apenas é possível decompor um dado sinal em $L^2(\mathbb{R})$ (espaço das funções quadrado-integráveis em \mathbb{R}), através de wavelets, como também é possível reconstruí-lo (MORLET E GROSSMAN, 1984).

Em 1985, Meyer construiu a segunda wavelet ortonormal. No caso antes da wavelet de Meyer apenas a wavelet de Haar era ortonormal (MEYER, 1985). Wavelets ortonormais constituem ferramentas interessantes na análise de sinais e possuem aplicações em diversos campos (DAUBECHIES, 1992; KRONLAND-MARTINET et al., 1988; LIU et al., 2003). Logo em seguida, em 1988, com base nos trabalhos de Meyer (1985; 1986) e Mallat (1989), principais autores no conceito da análise da multiresolução (do inglês, *Multiresolution Analysis* – MRA), Daubechies (1988) construiu a primeira função wavelet que é ao mesmo tempo ortonormal, com

suporte compacto⁷ e continuamente diferenciável. Logo em seguida, em 1992, sendo já conhecido que a ortogonalidade não é essencial na representação de sinais, Daubechies publicou a sua contribuição sobre o uso de *frames* (conceito desenvolvido por DUFFIN e SHAEFFER, 1952) para a construção adequada de *wavelets* não-ortogonais (também chamada de *wavelet frames*), cujas funções de bases são redundantes, possuindo forte aplicação no campo da identificação de sistemas não-lineares (SMITH, 2007; TADAYONI, Xie e GORDON, 2011; CAJUEIRO, KALID e Leizer, 2011 (a), (b), (c); LIN, HSU e CHUNG, 2012) e processamento digital de sinais (SHI e YANG, 2011; DONG et al., 2012).

Nas próximas seções deste capítulo são abordados alguns conceitos básicos sobre as transformadas wavelets. Tais conceitos são necessários para a compreensão da função não-linear usada no modelo NARX e no modelo de Hammerstein-Wiener, a *wavelet network*.

3.2 O QUE É A WAVELET?

Wavelets são funções bastante simples, que possuem duração limitada, valor médio zero e energia concentrada ao redor de um ponto no tempo, podendo ser usadas como uma ferramenta analítica para processamento de sinal, modelagem matemática, análise numérica, dentre outros (DAUBECHIES, 1992). Estas funções podem formar um conjunto infinito de funções de base, as quais são localizadas simultaneamente na escala (frequência) e no tempo possibilitando decompor um sinal em diferentes componentes de frequência, permitindo o estudo de cada um destes componentes com a resolução correspondente a sua escala. Isto faz da wavelet uma poderosa ferramenta na análise (decomposição) e síntese (reconstrução) de fenômenos transientes, não-estacionários, ou variantes no tempo.

Para uma função ser classificada como *wavelet* (ψ) ela precisa atender as seguintes exigências:

- 1) O valor médio da wavelet no domínio do tempo deve ser zero:

⁷ Diz-se que uma dada função (ex: função f) tem suporte compacto, se existe um intervalo fechado e limitado, fora do qual a função é zero (ou seja, $f(x) = 0$). Em outras palavras, a função tem um começo finito e um fim finito (diferente dos senos e cosenos que são infinitos). A importância de ter suporte compacto é que quando se encaixa esta função ao sinal analisado, se obtém um resultado localizado em vez de um resultado global.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (3.1)$$

2) A função deve possuir energia finita:

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty \quad (3.2)$$

3) A função deve satisfazer a condição de admissibilidade:

$$C_\psi = 2\pi \int_{-\infty}^{+\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega \quad (3.3)$$

onde $\hat{\psi}$ é a transformada de Fourier de ψ , sendo que $\psi \in L^2(\mathbb{R})$. Vale ressaltar que a transformada wavelet inversa só existe para $0 < C < \infty$. Isto significa que o sinal analisado pode ser reconstruído sem perda de informação (DAUBECHIES, 1992). Para uma análise detalhada sobre tais exigências o leitor deve-se reportar ao livro de Daubechies (1992).

3.3 DIFERENÇAS ENTRE A TRANSFORMADA DE FOURIER POR JANELAS E A TRANSFORMADA WAVELET

Sabe-se que a transformada de Fourier (FOURIER, 1822) utiliza funções de base unicamente senoidais e é capaz de representar sinais apenas no domínio da frequência:

$$(Tf)(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-j\omega t} dt \quad (3.4)$$

em que Tf denota a transformada de Fourier da função $f(t)$. Por outro lado, a transformada de Fourier por janelas (do inglês, *short-time Fourier transform* – STFT ou *windowed Fourier transform* – WFT ou *Gabor Transform*), também conhecida como transformada de Gabor (GABOR, 1946), permite obter a localização tempo-frequência de um sinal:

$$(Tf)(\omega, s) = \int_{-\infty}^{+\infty} f(t)g(t-s)e^{-j\omega t} dt \quad (3.5)$$

onde após fixar a largura da janela $g(t)$, o sinal é seccionado em segmentos iguais e a respectiva WFT é obtida. A Figura 3.3 exemplifica o plano tempo-frequência para a

WFT.

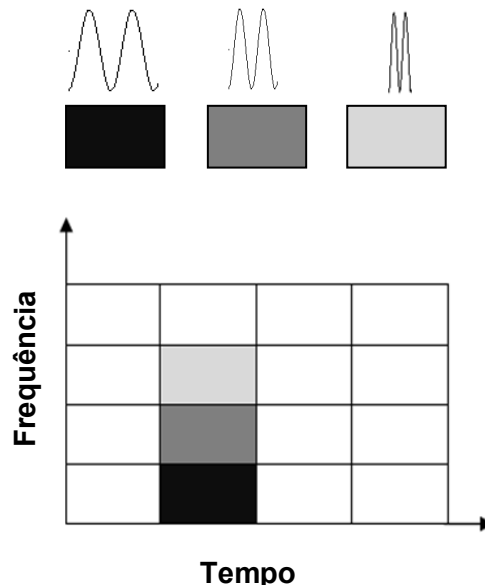


Figura 3.3: Plano tempo-frequência para a transformada por janela de Fourier com destaque nas funções de base de Fourier.

Como na WFT são usadas janelas de comprimento único para todas as frequências do sinal, conseqüentemente a resolução da análise é a mesma em todos os locais no plano tempo-frequência.

Diferente da WFT que possui uma janela com largura fixa que se translada durante todo o sinal analisado com a mesma resolução, a *transformada wavelet* (do inglês, *continuous wavelet transform* - CWT) possui um parâmetro de escala que varia a largura da janela, e permite decompor um sinal em diferentes componentes de frequência. Como além de variar a largura da janela, a função wavelet também se desloca sobre o sinal, é possível analisar a mesma seção do sinal em diferentes resoluções, que podem ser das mais grosseiras (“enxergando o sinal de longe”) às mais finas/detalhadas (“enxergando o sinal de perto”). A CWT é descrita por:

$$(T^{wav} f(x))(a, b) = w(a, b) = \int_{\mathbb{R}} f(x) \psi_{a,b}(x) dx, \quad (3.6)$$

onde,

$$\psi(x) = \frac{1}{|\sqrt{a}|} \psi\left(\frac{x-b}{a}\right) \quad (3.7)$$

é a função wavelet, também chamada de função protótipo ou wavelet mãe; $a > 0$ e b

$\in \mathbb{R}$ são variáveis contínuas, chamadas, respectivamente, parâmetros de dilatação e translação. O parâmetro de dilatação é responsável por alongar ou comprimir a função de base. Já o parâmetro de translação é responsável em deslocar a wavelet pelo sinal analisado. Aplicando a transformada wavelet inversa, a função $f(x)$ pode ser novamente obtida,

$$f(x) = \frac{1}{C_\psi} \int_0^\infty \int_{\mathbb{R}} \frac{1}{a^2} \frac{1}{|\sqrt{a}|} w(a,b) \psi\left(\frac{x-b}{a}\right) db da, \quad (3.8)$$

onde $w(a,b)$ é o resultado do produto interno $\langle f, \psi_{a,b} \rangle$, e C_ψ é a condição de admissibilidade definida pela equação (3.3).

A Figura 3.4 exemplifica como se dá a localização no plano tempo-escala associado com a transformada wavelet. No caso, os componentes de baixa frequência do sinal são capturados utilizando escalas maiores; já os componentes de alta frequência do sinal são capturados com escalas menores, conseqüentemente, a resolução da análise será diferente para cada seção do sinal. Tal análise resulta em uma decomposição na forma piramidal, uma vez que todo o sinal é analisado com valores de dilatação exponencialmente distribuídos (MALLAT, 1989).




Figura 3.4: Funções de base wavelet cobrindo o plano tempo-escala.

3.4 A TRANSFORMADA WAVELET DISCRETA

A CWT precisa ser discretizada a fim de poder ser implementada em computadores digitais, para análise de sinais e imagens (dentre outras aplicações) discretamente amostrados. Para a obtenção da versão discreta da CWT, ou seja, a transformada wavelet discreta (em inglês: *discrete wavelet transform* (DWT)), os sinais de integração são substituídos por um somatório finito e os parâmetros de dilatação e translação da wavelet mãe que variam de modo contínuo (ver equação (3.7)), são substituídos por valores discretos. No caso, a é substituído por a_0^m e b é substituído por $nb_0a_0^m$, os quais são, respectivamente, o passo de dilatação e translação. Desta forma, tem-se a wavelet discretizada:

$$\psi_{m,n}(x) = \frac{1}{|\sqrt{a_0^m}|} \psi\left(\frac{x - nb_0a_0^m}{a_0^m}\right) = a_0^{-m/2} \psi(a_0^{-m}x - nb_0) \quad (3.9)$$

onde $a_0 > 1, b_0 > 0$ e $m, n \in \mathbb{Z}$. Em se tratando de DWT, é possível obtê-la usando diferentes tipos de funções base, dos quais se dividem basicamente em duas categorias: bases redundantes (wavelet frames) (DUFFIN E SCHAEFFER, 1957; KUGARAJAH E ZHANG, 1995) e bases ortonormais. Sendo que as últimas foram aprimoradas a partir do trabalho da Mallat (1989), intitulado "Análise da multiresolução", que foi o ponto de partida para criação das funções wavelets elegantes realizadas por Daubechies (1988; 1992).

3.5 WAVELET FRAMES

O conceito de *Frame* foi originalmente desenvolvido por Duffin e Schaeffer (1957) e discutido em Daubechies (1992) para analisar a estabilidade, integridade e redundância de uma representação discreta de um sinal por meio de wavelets. Um *frame* é um conjunto de vetores $\{\psi_{m,n}; m, n \in \mathbb{Z}\}$ que permite descrever um dado sinal $f \in L^2(\mathbb{R})$ por meio de um somatório finito e não-ortogonal de termos dado pela seguinte equação:

$$f(x) = \sum_{m,n} \langle f, \psi_{m,n} \rangle \psi_{m,n}(x) \quad (3.10)$$

onde $\psi_{m,n}$ é a função wavelet discreta dada pela equação (3.9) e $\langle f, \psi_{m,n} \rangle$ é o

coeficiente da função wavelet (que após a obtenção de (3.9) agora pode ser chamado de $w_{m,n}$). Para que a reconstrução de f na equação (3.10) seja possível, a seguinte condição de frame necessita ser satisfeita:

$$A\|f\|^2 \leq \sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 \leq B\|f\|^2 \quad (3.11)$$

onde $\|\cdot\|$ denota a norma da função, sendo que $\|f\|^2$ é a energia da função f , A e B são independentes de f ; A e B denotam, respectivamente, o limite inferior e superior do *frame*.

Se, portanto, a equação (3.11) é satisfeita, a família de funções $\psi_{m,n}$ com $m,n \in \mathbb{Z}$ constitui um frame de $L^2(\mathbb{R})$. A prova matemática da restrição (3.11) pode ser vista no artigo de (KUGARAJAH E ZHANG, 1995) e no livro de Daubechies (1992). Ainda no artigo de Kugarajah e Zhang (1995) a *wavelet frame* de uma dimensão é generalizada para o caso de múltiplas dimensões. O leitor interessado em conhecer como o coeficiente $w_{m,n}$ é computado deve-se reportar ao livro de Daubechies (1992).

3.5.1 Wavelet Frames Radiais

Wavelet frame consistindo de funções *wavelet* radiais são naturalmente estruturas de escala única em $L^2(\mathbb{R}^d)$. *Wavelets frames* radiais de escala única possuem o mesmo índice de dilatação em todas as dimensões.

Uma função wavelet $\psi(x) \in \mathbb{R}^d$ é radial se possui simetria radial

$$\{\hat{\psi}(\omega) = \hat{\phi}(\|\omega\|) : \omega \in \mathbb{R}^d\} \quad (3.12)$$

e satisfaz a seguinte condição de admissibilidade

$$C_\psi = (2\pi)^d \int_0^\infty \frac{|\hat{\psi}(h\omega)|^2}{h} dh < \infty \quad (3.13)$$

onde $\hat{\psi}(\omega)$ é a transformada de Fourier de $\psi(x)$, com $x \in \mathbb{R}^d$, e $\|x\| = \sqrt{x^T x}$ é a norma Euclidiana (Kugarajah e Zhang, 1995).

Kugarajah e Zhang (1995) mostram que uma *wavelet frame* radial de escala

única multidimensional $f \in L^2(\mathbb{R}^d)$ pode ser construída pela dilatação a transladação de uma única wavelet mãe radial

$$f = \{ \psi_{m,n}(x) = a_0^{-dm/2} \psi(a_0^{-m}x - nb_0) : m \in \mathbb{Z}, n \in \mathbb{Z}^d \} \quad (3.14)$$

onde $a_0 > 1$ e $b_0 > 0$. Wavelets radiais que satisfazem as equações (3.12) e (3.13) são muito utilizadas na identificação de sistemas devido à facilidade de implementação e devido à forma como se concentram no espaço tempo-frequência (Zhang, 1997). Para um entendimento detalhado sobre a construção de wavelet frames de escala única o leitor deve-se reportar ao artigo de Kugarajah e Zhang (1995) e Zhang (1997).

É importante ressaltar que neste trabalho as wavelets frames radiais de escala única são usadas para compor a *wavelet network*.

3.6 WAVELET CONTÍNUA E DISCRETA PARA DIMENSÕES ELEVADAS

Qualquer função $f \in L^2(\mathbb{R}^d)$ pode ser decomposta e representada por funções wavelets, desde que estas wavelets satisfaçam a condição dada pela equação (3.13),

$$w(a, b) = \int_{\mathbb{R}^d} f(x) \frac{1}{|\sqrt{a^d}|} \psi\left(\frac{x-b}{a}\right) dx \quad (3.15)$$

e a sua inversa também pode ser escrita:

$$f(x) = \frac{1}{C_\psi} \int_0^\infty \int_{\mathbb{R}^d} \frac{1}{a^{d+1}} \frac{1}{|\sqrt{a^d}|} w(a, b) \psi\left(\frac{x-b}{a}\right) db da \quad (3.16)$$

onde $\psi(x)$ é a função wavelet mãe, a segunda derivada da função gaussiana. Discretizando a equação (3.16), tem-se:

$$f(x) = \sum_{m,n} \omega_{m,n} a_0^{-dm/2} \psi(a_0^{-m}x - nb_0) \quad \{m \in \mathbb{Z}, n \in \mathbb{Z}^d\} \quad (3.17)$$

onde o termo $a_0^{-dm/2}$ é o fator de normalização, a_0 é o tamanho do passo de dilatação, b_0 é o tamanho do passo de translação. No livro de Daubechies (1992),

seção 2.6, a função wavelet contínua é apresentada para dimensões maiores do que \mathbb{R}^1 . Já no trabalho de Kugarajah e Zhang (1995), os vários aspectos da construção de funções wavelet discreta multidimensionais é vista em detalhes.

3.7 WAVELET NETWORK

Trabalhos importantes no estudo das decomposições wavelets, como o trabalho de Daubechies (1992), possibilitou a Zhang e Benveniste (1992) o desenvolvimento da *wavelet network* (também chamada de *wavenet*). A *wavelet network* foi proposta a princípio como alternativa à rede neural feedforward. De acordo com Zhang (1997), a ausência de métodos mais eficientes para determinar a estrutura da rede e os parâmetros dos neurônios fazem com que o desempenho das RNAs muitas vezes não seja satisfatório. Basicamente, a *wavelet network* é uma decomposição *wavelet* implementada em uma rede neural de uma camada escondida, onde as *wavelets* são funções de ativação dos neurônios escondidos. De acordo com Zhang (1997), graças ao uso heurístico da transformada wavelet, para ajustar o valor inicial dos parâmetros da rede a partir de dados observados, a *wavenet* tem mais facilidade para superar o problema de mínimos locais do que as redes neurais. Vale ressaltar que diferente das RNAs, as funções base da decomposição wavelet não são rígidas, uma vez que se adaptam aos dados observados (ZHANG, 1997). O resultado da combinação da decomposição wavelet e das redes neurais se resume em uma ferramenta com métodos construtivos eficientes (ver: ZHANG E BENVENISTE, 1992; SJÖBERG ET. AL., 1995; ZHANG; 1997; SAFAVI E ROMAGNOLI, 1997; TADAYONI, XIE E GORDON, 2011; LIN, HSU E CHUNG, 2012), para a escolha da estrutura e determinação dos parâmetros da rede, e capaz de resolver problemas de elevada dimensão.

A *wavelet network*, pode ser vista por duas diferentes perspectivas, as quais são: multiresolução (SAFAVI AND ROMAGNOLI, 1997); e wavelet frames (ZHANG, 1997). Na primeira abordagem as wavelets utilizadas na expansão formam bases ortogonais. Na segunda, a expansão é construída usando wavelets não-ortogonais. Nesta dissertação, considera-se apenas esta última abordagem. Tal escolha simplifica o uso das wavelet networks em sistemas com alta dimensão de entrada. Isto porque para gerar bases ortonormais em $L^2\mathbb{R}^d$ de escala única necessita-se de

$2^d - 1$ funções wavelets mãe, por outro lado a geração de wavelet frames de escala única multidimensionais somente necessita de uma única wavelet mãe.

Nesta dissertação, as wavelets networks são usadas para resolver o seguinte problema de estimação:

$$y = f(x) + e \quad (3.18)$$

onde f é a wavelet network e e é um ruído branco independente de x .

Na próxima subseção é detalhada a construção da wavelet network baseada em frames, bem como é abordado o seu algoritmo de treinamento.

3.7.1 Construção da Wavelet Network

Se os parâmetros da transformada wavelet inversa dada na equação (3.16), w , a e b , forem discretizados de acordo com os dados de treinamento, então a discretização adaptativa da transformada wavelet inversa dada pela equação (3.17) pode ser chamada de wavelet network. Como mencionado anteriormente, esta estrutura pode ser considerada como uma rede neural, cujas wavelets são funções de ativação da camada escondida, como mostra Figura 3.5.




Figura 3.5: Estrutura geral da wavelet network.

Em aplicações práticas é impossível construir a *wavelet network* usando um conjunto infinito de funções *wavelet frames* radiais, portanto as wavelets na equação

(3.17) necessitam ser truncadas em um conjunto finito⁸:

$$E = \{ \psi_{m,n}(x) = \sum_{m,n} \omega_{m,n} \psi(a_0^{-m}x - nb_0) : m \in S_a, n \in S_b(m) \} \quad (3.19)$$

onde E é a biblioteca de wavelets obtidas após a realização do truncamento, x é o conjunto de dados de treinamento, $S_a \subset \mathbb{Z}$ e $S_b \subset \mathbb{Z}^d$; sendo que o maior índice de dilatação corresponde ao tamanho do domínio da função.

Como é possível observar na equação (3.19), o problema de treinar a wavelet network consiste em escolher os valores de $\omega_{m,n}$, S_a , S_b , a_0 e b_0 de modo a se obter a saída esperada com o menor desvio possível. Lembrando que ψ , a_0 e b_0 são escolhidos de modo a se obter uma função wavelet radial em $L^2(\mathbb{R}^N)$. Como discutido anteriormente neste capítulo, diferente das redes neurais artificiais, a decomposição wavelet naturalmente sugere a inicialização da wavelet network (ZHANG, 1997). Como o truncamento da decomposição wavelet é normalmente realizado sem levar em conta o espaçamento dos dados, pode-se imaginar que a biblioteca E estará repleta de wavelets cujo suporte não contém nenhum dado de estimação. Desta forma, a fim de selecionar apenas as wavelets mais representativas para compor a biblioteca E , considerando as wavelets $\psi_{m,n}$ que formam a biblioteca E na equação (3.19) como regressores, Zhang (1997) propôs o uso de técnicas de análise de regressão para encontrar as wavelets mais adequadas para compor a função f .

A seguir, é descrito o processo de inicialização e treinamento da *wavelet network*. Tal descrição é baseada nos trabalhos de Kugarajah and Zhang (1995) e Zhang (1997) e se aplicam quando a wavelet network é usada como função f do modelo NARX (ver seção 2.1.5.1). O principal objetivo desse algoritmo, de acordo com Zhang (1997), é o de aumentar a eficiência computacional, se comparado com o método usado por Zhang (1992) que envolvia o algoritmo backpropagation. Para o caso em que a *wavelet network* é usada no modelo de Hammerstein-Wiener, qualquer algoritmo de otimização não-linear pode ser usado. O leitor pode se reportar ao livro de Nelles (2001) para uma abordagem completa sobre métodos de otimização não-linear.

⁸ Esta operação é semelhante a manter um número finito de termos na decomposição wavelet discreta para aproximar a função decomposta. O leitor deve-se reportar ao livro de Daubechies (1992) para maiores detalhes.

3.7.2 Procedimento para inicialização e treinamento da *wavelet network*

Na prática a *wavelet network* não usa os coeficientes obtidos pela aplicação direta da decomposição wavelet discreta⁹. Ao invés disso, inicia-se a rede escolhendo-se os parâmetros de dilatação e translação de tal forma que eles constituam uma estrutura regular piramidal (assim como é obtido na decomposição wavelets discreta). Em seguida, guardam-se os valores de m e n que minimizam a função penalidade:

$$V = \sum_{k=0}^N \|y(k) - f(x(k))\|^2 \approx 0$$

em que

$$f(x) = \sum_{m,n} \omega_{m,n} \psi(a_0^{-m}x - nb_0)$$

é a *wavelet network*; desta forma, a obtenção dos pesos da rede, $\omega_{m,n}$, se reduz a um problema que pode ser resolvido aplicando o método dos mínimos quadrados.

Para cada ponto de treinamento $x = \{(u(1), \dots, u(N))\}$ do conjunto finito de comprimento N , é determinado o índice das wavelets (I) cujo suporte contém ao menos um ponto de dado amostrado

$$I(k) = \{(m, n): u(k) \in S_{m,n}\},$$

em que $S_{m,n}$ é o suporte da função wavelet. Após determinar o índice I , constrói-se o conjunto de wavelets W candidatas a serem funções de ativação para estimação da função f

$$W = \{\psi_{m,n}: (m, n) \in I_1 \cup I_2 \cup \dots \cup I_N\}$$

Os procedimentos dados anteriormente resolvem o problema das wavelets “vazias”. No entanto, como até o momento apenas as variáveis de entrada foram consideradas para estimar a saída $y(k)$, muitos termos na biblioteca de wavelets

$$W = \{\psi_j\}, j = 1, \dots, L$$

são redundantes para estimar f .

⁹ Isso porque o estimador sofre da maldição da dimensionalidade. Este fenômeno diz que a complexidade dos estimadores aumenta de modo exponencial com a dimensão de entrada.

Considerando as wavelets presentes em W como regressores, o próximo passo consiste em selecionar o melhor subconjunto de W ($M \leq L$) que abranja todo o espaço do vetor de saída y o mais próximo possível.

Seleção das Wavelets pela ortogonalização:

Assumindo *a priori* que o tamanho do subconjunto de W é conhecido, em outras palavras, o valor de M já é conhecido, o algoritmo modificado de Gram-Schmidt (HAN E NEUMANN, 2007) é aplicado para ortogonalizar as *wavelets* a fim de reduzir o custo computacional e conseqüentemente tornar mais simples a seleção das *wavelets* mais adequadas a partir de W .

Considerando a princípio, a seguinte notação matricial:

$$\psi_j = [\psi_j(x(1)) \dots \psi_j(x(N))]^T$$

onde $\psi_j \in W$ é o conjunto de *wavelets* normalizadas, a coleção de ψ_j , com $j = 1, \dots, L$ forma um conjunto em V

$$V = \{\psi_1, \dots, \psi_L\}$$

onde vale ressaltar que $\psi_j^T \psi_j = 1$ e $x(1), \dots, x(N)$ é a entrada de treinamento. Da mesma forma, a saída amostrada também pode ser escrita de forma matricial:

$$Y = [y_1 \dots y_N]^T$$

O objetivo do algoritmo heurístico proposto por (ZHANG, 1997), que é na verdade uma sutil modificação do algoritmo proposto por Chen et al. (1989), é o de selecionar as *wavelets* em V que abranja de forma linear, com os vetores previamente selecionados, o espaço mais próximo de Y . Este algoritmo lida com a *decomposição QR*, já discutida na seção 2.1.7.2, que nessa dissertação é calculada pelo algoritmo modificado de Gram-Schmidt (HAN E NEUMANN, 2007). Tal procedimento é descrito a seguir.

Para iteração i , denote por l_i o índice da *wavelet* selecionada de W . Sendo i a iteração atual, então $\psi_{l_1}, \dots, \psi_{l_{i-1}}$ foram selecionadas em iterações anteriores. A fim de reduzir o custo computacional, as *wavelets* selecionadas na iteração corrente ψ_j são ortonormalizadas para as anteriormente selecionadas, do seguinte modo:

$$q_{l_i} = \psi_{l_i}$$

$$p_{l_j} = \psi_{l_j} - \left[(\psi_{l_j}^T q_{l_1}) q_{l_1} + \dots + (\psi_{l_j}^T q_{l_{j-1}}) q_{l_{j-1}} \right]$$

$$j = 2, 3, \dots, i - 1$$

$$q_{l_j} = \frac{p_{l_j}}{\sqrt{p_{l_j}^T p_{l_j}}}, j = 2, \dots, i - 1$$

onde q_{l_j} é a versão ortonormalizada de ψ_{l_j} , para $j = 1, \dots, i - 1$. Agora, ortogonalizando os vetores restantes ψ_j para $q_{l_1}, \dots, q_{l_{i-1}}$, tem-se:

$$p_j^{(i)} = p_j^{(i-1)} - (\psi_j^T q_{l_{i-1}}) q_{l_{i-1}}$$

em que,

$$p_j^{(0)} = \psi_j$$

Agora que $q_{l_1}, \dots, q_{l_{i-1}}$ e p_j são ortogonais, a melhor ψ_j a ser escolhida para a iteração atual corresponde à p_j que mais se aproxima de Y . Sendo assim, escolhe-se:

$$l_i = \arg \max(j) \frac{(p_j^{(i)})^T Y}{\sqrt{(p_j^{(i)})^T p_j^{(i)}}}$$

$$q_{l_i} = \frac{p_j^{(i)}}{\sqrt{(p_j^{(i)})^T p_j^{(i)}}}$$

e encontra-se as *wavelets* mais relevantes..

Após S iterações as *wavelets* $\psi_{l_1}, \dots, \psi_{l_S}$ foram selecionadas. A *wavelet network* pode então ser construída, como:

$$\hat{f}_s(x) = \sum_{i=1}^S w_{l_i} \psi_{l_i}(x) \quad (3.20)$$

onde a obtenção dos pesos da rede (w_{l_i}) se reduz a um problema de mínimos quadrados,

$$Y = \Psi \varpi$$

o qual é resolvido aplicando-se a *decomposição QR* (vista na Seção 2.1.7.2); onde $\varpi = [w_{l_1}, \dots, w_{l_S}]^T$ e $\Psi = [\psi_{l_1}, \dots, \psi_{l_S}]$. Observa-se que a diferença entre \hat{f}_S e f , deve-se ao fato de que \hat{f}_S foi obtida a partir de f , por meio do processo de seleção de *wavelets* descrito anteriormente.

Para o uso da *wavelet network* torna-se necessária uma série de considerações:

- pelo fato de ser radial e devido à boa localização tempo-frequência, considera-se a função wavelet ψ como a segunda derivada da função Gaussiana, o chamado “chapéu-mexicano”:

$$\psi(x) = (\dim(x) - \|x\|^2) e^{-\frac{\|x\|^2}{2}} \quad (3.21)$$

onde $\|x\|^2 = x^T x$. A Figura 3.6 mostra o gráfico correspondente a equação (3.21).




Figura 3.6: Função wavelet ψ . A segunda derivada da função Gaussiana, o chamado “chapéu mexicano”.

- toma-se $\{a_0^{-m} x, nb_0\}$ na forma de grade diádica, isto é, $a_0 = 2$ e $b_0 = 1$;
- a fim de reduzir a dimensionalidade dos dados de entrada, condicionando

melhor o sinal para a estimação da função f , aplica-se à entrada x a técnica de análise dos componentes principais (PCA) (Nelles, 2001).

No que diz respeito à seleção do melhor subconjunto de W para estimação de f , em outras palavras como escolher o tamanho de S . O objetivo é avaliar a performance de \hat{f}_S , para diferentes combinações de S . Para tal, utiliza-se a validação cruzada generalizada (do inglês, *generalized cross-validation* (GCV)):

$$GCV = \frac{1}{N} \sum_{k=1}^n (\hat{f}_S(u(k)) - y(k))^2 + 2S \frac{1}{N} \sigma_e^2 \quad (3.22)$$

onde GCV é minimizado com respeito a S ; \hat{f}_S é a aproximação dada pela *wavelet network* ao sinal de entrada $u(k)$; S é o número de funções de base da rede; N é o tamanho dos dados amostrado; $y(k)$ é a saída medida; e σ_e^2 é a variância do ruído no modelo de regressão dado pela equação (3.18).

Em princípio, funções *wavelets* dilatadas e transladadas são suficientes para formar um *frame*. No entanto, as como funções *wavelet* são geralmente "filtros passa-faixa", no sentido de que seus espectros são (quase) concentrados dentro de alguma área fora da origem, tais funções tendem a apresentar oscilações irregulares (JENSEN E COUR-HARBO, 2001). A fim de melhorar a regularidade do estimador, uma função de escala φ , que é equivalente a um "filtro passa-baixas"

$$\varphi(x) = e^{-\frac{|x|^2}{2}} \quad (3.23)$$

é adicionada a *wavelet network*; a qual agora é reescrita do seguinte modo:

$$f(x) = \sum_{k=1}^{ns} a_{sk} \varphi(D_{sk}(x - r)Q - t_{sk}) + \sum_{k=1}^{nw} \omega_{wk} \psi(D_{wk}(x - r)Q - t_{wk}) \quad (3.24)$$

Onde r é a média do vetor de regressores ($1 \times m$), Q é uma matriz do subespaço não-linear ($m \times q$) obtida através da aplicação da análise dos componentes principais (PCA) aos regressores em x ; a_{sk} é o vetor de coeficientes associado com os scalons ($ns \times 1$), ω_{wk} é o vetor de coeficientes associado com os wavelons ($nw \times 1$), D_{sn} é a matriz de dilatação associada com os scalons ($ns \times 1$), D_{wn} é a matriz de

dilatação associada com os wavelons ($nw \times 1$); t_{sn} é a matriz de translação associada com os scalons ($ns \times q$), t_{wn} é a matriz de translação associada com os wavelons ($nw \times q$), ns é o número de scalons e nw o número de wavelons. Funções de escala e as funções wavelet são ambas utilizadas para diferentes escalas de dilatação, em uma estrutura semelhante à decomposição wavelet (JENSEN E COUR-HARBO, 2001).

A fim de tornar a *wavelet network* dada pela equação (3.24) mais sensível para captura das relações lineares presentes entre os dados de entrada e saída, uma função afim é adicionada, o que resulta em:

$$f(x) = \sum_{k=1}^{ns} a_{sk} \varphi(D_{sk}(x - r)Q - t_{sk}) + \sum_{k=1}^{nw} \omega_{wk} \psi(D_{wk}(x - r)Q - t_{wk}) + x(k)P\theta^T + l \quad (3.25)$$

onde $\theta \in \mathbb{R}^d$ é o parâmetro de conexão direta da entrada para a saída, $l \in \mathbb{R}$ é o offset de saída e P é uma matriz de subespaço linear ($m \times p$) obtida pela aplicação da análise dos componentes principais aos regressores de entrada (ZHANG, 1993(a)).

Agora que a estrutura final da *wavelet network* já é conhecida, é possível também redesenhar a Figura 3.5, a fim de se obter a Figura 3.7. Ressalta-se que na Figura 3.7 os sinais de entrada transformados são multiplicados pelo seu respectivo coeficiente de dilatação e em seguida são subtraídos do coeficiente de translação.

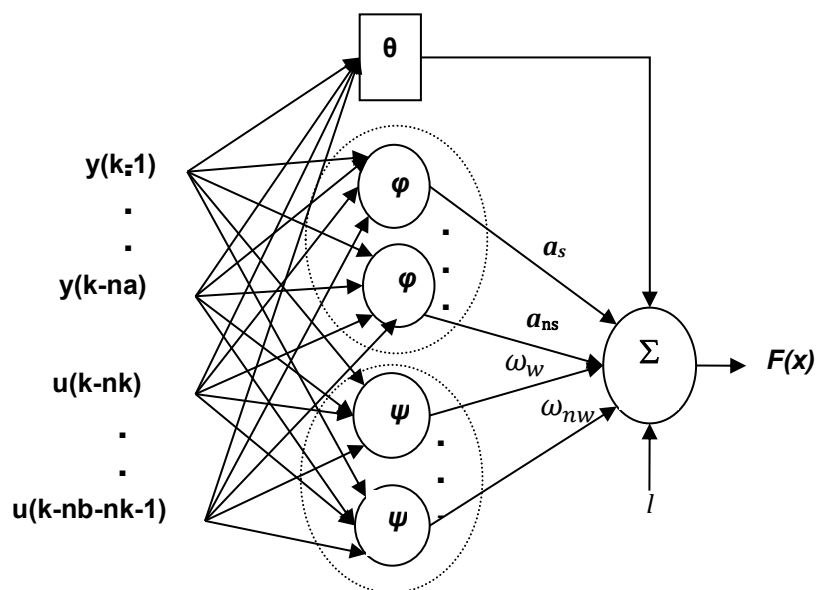


Figura 3.7: Estrutura da wavelet network.

3.8 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo tratou da construção da função não-linear, a *wavelet network*, a qual é usada no modelo NARX (estrutura F) e no modelo de Hammerstein-Wiener (estruturas f_1 e f_2). Foi visto que a wavelet network utilizada nesta dissertação é construída usando wavelets radiais não-ortogonais, as quais necessitam satisfazer a condição de *frame* vista na seção 3.5. Também foi visto que embora a estrutura seja não-linear, a mesma é linear nos parâmetros e portanto seus pesos ϖ podem ser estimados pelo método dos mínimos quadrados.

No próximo capítulo é descrito o método de elevação artificial por bombeio mecânico (BM). Tal descrição é útil para a compreensão do funcionamento do BM e da importância da carta dinamométrica.

4 BOMBEIO MECÂNICO E CARTAS DINAMOMÉTRICAS

Quando as pressões das formações produtoras de petróleo são insuficientes para promoverem a elevação do fluido produzido, faz-se necessário o uso de um método de elevação artificial que seja capaz de fornecer energia para elevação do fluido. Dentre os métodos de elevação artificial existentes, o mais usado em poços terrestres é o bombeio mecânico (BM). De acordo com Takacs (2000), cerca de 2/3 dos poços de petróleo produzindo fazem parte deste método. Nos Estados Unidos da América, o BM encontra-se instalado em aproximadamente 90% dos poços de petróleo (CUTLER E MANSURE, 2010). Dos 1.500 poços que operavam na Bahia em 2002, cerca de 500 poços eram equipados com este método (BARRETO FILHO, 2002).

Dentre as inúmeras vantagens no uso do BM destacam-se a simplicidade com relação ao projeto, custo, manutenção e consumo de energia; podendo ser adaptado a uma ampla gama de condições operacionais (CUTLER E MANSURE, 2010). Dentre as desvantagens, pode-se citar a limitação com a profundidade do poço e a dificuldade de uso em poços com desvio (COOK E GRAHAM, 2003).

4.1 COMPONENTES DO BOMBEIO MECÂNICO

A Figura 4.1 mostra os principais componentes do BM. Tais componentes dividem-se em elementos de superfície e elementos de subsuperfície (TAKACS, 2000), como descritos a seguir:

Elementos de superfície:

No que diz respeito aos elementos de superfície, tais elementos são partes integrantes da *unidade de bombeio*:

- Motor: fornece energia para o sistema;
- Unidade de bombeio (UB): Converte a energia fornecida pelo motor em movimento alternativo vertical.




Figura 4.1: Componentes principais do bombeio mecânico.

Fonte: (Ordoñez, 2008)

Elementos de subsuperfície:

- Coluna de hastes: fica diretamente conectada a haste polida. A coluna de hastes é localizada no interior da tubulação de produção, e tem a função de transmitir o movimento alternativo gerado pela UB para a bomba de fundo;
- Bomba de subsuperfície: A Figura 4.2 mostra em detalhe a bomba de subsuperfície. Esta bomba desloca o fluido apenas em um sentido de movimento alternativo, o sentido ascendente. Sendo composta por parte fixa: camisa de bomba – onde é alojada a válvula de pé; e partes móveis: pistão – onde é alojada a válvula de passeio. As válvulas são autooperadas pela pressão do fluxo de fluido.




Figura 4.2 Partes da bomba de fundo.

(Fonte: Silva et al., 2002.)

4.2 CICLO DE BOMBEIO

O ciclo de bombeio ideal é dado do seguinte modo (ver Figura 4.3): no curso ascendente (no inglês, *upstroke*), a válvula de passeio encontra-se fechada, devido à pressão hidrostática no interior da bomba de fundo ser menor do que a pressão hidrostática do fluido acima do pistão; e a válvula de pé deve estar aberta de modo a permitir que o fluido oriundo da formação seja admitido para dentro da camisa de bomba. Neste momento, o fluido acima e dentro do pistão é levantado para fora da camisa, enquanto mais fluido é bombeado para dentro do poço (BARRETO FILHO, 1993). A quantidade de fluido produzido (no curso ascendente) é equivalente ao volume do cilindro definido pela área do pistão da bomba de fundo e pelo curso útil do pistão (BARRETO FILHO, 2002). No curso ascendente, o peso do fluido que é deslocado pela haste de bombeio ocasiona um alongamento da coluna de hastes.

No curso descendente, a válvula de passeio encontra-se normalmente aberta e a válvula de pé fechada, devido à pressão da coluna hidrostática em cima dela ser maior que a pressão de admissão da bomba de fundo.




Figura 4.3: Ciclo de bombeio. Curso ascendente (a), e curso descendente (b).

(Fonte: Silva et al., 2002)

4.3 CARTA DINAMOMÉTRICA

A carta dinamométrica é um instrumento utilizado no diagnóstico do bombeio mecânico, pois a haste reage com as cargas (sobre coluna de hastes) que são impostas pelo poço. De acordo com Takacs (2002) e Barreto Filho (2002), dentre as diversas informações que podem ser obtidas através da carta dinamométrica, destacam-se:

- início e final do curso ascendente;
- início e final do curso descendente;
- determinação da carga, torque e potência requerida para a unidade de bombeio;
- melhoria das condições de funcionamento da bomba como velocidade de bombeio e comprimento do curso, bem como detecção de condições de falha;
- determinação das cargas que atuam na unidade de bombeio e na haste polida;
- ajuste do contrabalanço da unidade de bombeio.

Existem dois tipos de carta dinamométrica: a **carta de superfície (CDS)** e a **carta de fundo (CDF)**. A CDS é um traçado contínuo da posição e carga suportada pela haste polida durante um ciclo de bombeio, e é registrada por meio de dinamômetro ou célula de carga e sensor de posição, os quais devem ser acoplados à haste polida. A CDF é calculada a partir da CDS (GIBBS E NEELY, 1966), e representa os efeitos gerados pela carga atuante na bomba de fundo durante um ciclo de bombeio. A necessidade em obter a CDF deve-se ao fato de que a CDS nem sempre permite um diagnóstico completo de desempenho das condições existentes na bomba de fundo; especialmente em poços fundos contendo unidade de bombeio funcionando a alta frequência, onde a elasticidade das hastes e atritos distorcem os padrões mostrados pela CDS (BARRETO FILHO, 1993). Por outro lado, para poços rasos a CDS pode ser eficaz no diagnóstico de desempenho da bomba.

A Figura 4.4 ilustra uma CDS para uma condição normal, onde é possível obter informações, como: início, fim, e desenvolvimento do curso das hastes; o peso do fluido sobre o pistão; a máxima e mínima carga suportada pela haste polida; efeito dos contrapesos; vazamento na válvula de pé e na válvula de passeio.




Figura 4.4: Carta dinamométrica de superfície (CDS).

Fonte: oilproduction.net (adaptado pelo autor).

Ressalta-se que em poços rasos, os padrões ilustrados para a CDF podem também ser obtidos diretamente pela CDS, como ocorre no caso experimental descrito neste trabalho.

Na próxima subseção são descritos dois diferentes padrões de CDF, os quais representam as situações mais comumente encontradas na elevação artificial por bombeio mecânico. Tais descrições tem como base o trabalho de dissertação de mestrado de Bezerra (2010).

4.3.1 CDF indicando condição normal

A Figura 4.5 mostra o traçado de uma CDF típica, obtida em poços cuja unidade de bombeio opera sob a condição de bombeamento normal, a baixa velocidade; e cuja coluna de produção não se encontra ancorada ao revestimento.

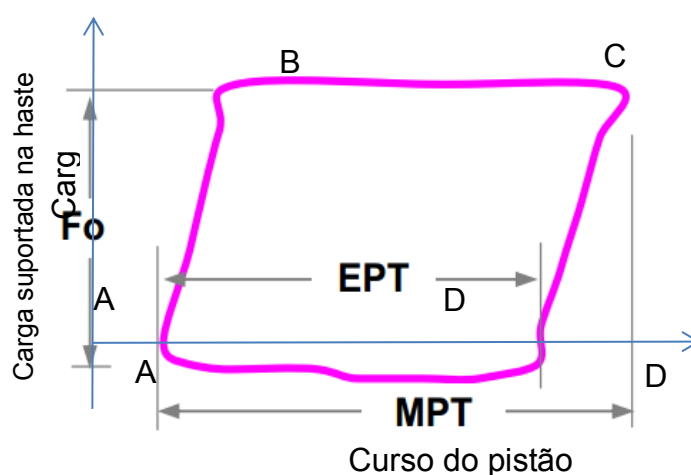


Figura 4.5: Carta dinamométrica típica de poços rasos. Situação em que o curso efetivo do pistão é menor que o máximo curso do pistão.

Fonte: oilproduction.net (adaptado pelo autor).

O ponto **A** representa o momento onde o curso da haste de bombeio inicia o movimento ascendente. Nesse instante, o peso do fluido é transferido, gradualmente, para a válvula de pé, conforme as hastes se esticam para suportar a carga do fluido, encontrando-se totalmente esticada no ponto **B**. Do ponto **B** para o **C**, o fluido é elevado pelas hastes enquanto mais fluido proveniente da formação é admitido para o interior da camisa. No ponto **C**, a válvula de pé é fechada assim que o pistão começa a descer; a válvula de passeio permanece fechada até que a pressão dentro da bomba seja ligeiramente maior do que a pressão de descarga da bomba. Logo em seguida, a válvula de passeio abre e a carga do fluido é transferida para a válvula de pé, chegando ao ponto **D**. De **D** para **A**, o pistão está descendo e ao mesmo tempo um volume de fluido invade o pistão. Enquanto na superfície ocorre uma pequena produção, devido a imersão da coluna de hastes no fluido.

Ainda com relação à Figura 4.5, é possível visualizar a diferença entre o máximo curso da bomba (MPT - no inglês, *maximum plunger travel*) e o curso efetivo da bomba (EPT - no inglês, *effective plunger travel*).

Considerando a coluna de produção ancorada ao revestimento e inelástica, para as mesmas condições em que a carta dinamométrica da Figura 4.5 foi gerada, esta pode ser redesenhada como mostrada a Figura 4.6.




Figura 4.6: CDF de um SBM operando sob condição normal.

Fonte: oilproduction.net (adaptado pelo autor)

Com relação à Figura 4.6, observa-se que a transição do ponto A para o B se dá de modo quase que instantâneo, assim como a transição do ponto C para o D; e que o EPT é igual ao MPT.

4.3.2 CDF indicando pancada de fluido

A Figura 4.7 mostra a carta de fundo para a condição de pancada de fluido. Embora a condição de pancada seja visível somente no ciclo de descendente, o problema da pancada de fluido pode ter origem no ciclo ascendente, quando a camisa não está suficientemente cheia pelo fluido. Isto acontece caso exista alguma restrição interferindo a passagem de fluido pela válvula de pé, ou caso a quantidade de fluido fornecida pelo reservatório não seja suficiente para ser admitida no poço. Consequentemente, como não há fluido suficiente no poço para reduzir o movimento da bomba no ciclo descendente, a mesma se choca violentamente com o fluido restante no fundo do poço, ocasionando uma diminuição abrupta da carga na haste polida. Este choque gera desgaste dos equipamentos de superfície, bem como dos

equipamentos de fundo. Além do mais, como a quantidade de fluido disponível é insuficiente para preenchimento completo da bomba, a condição de pancada de fluido reduz drasticamente a eficiência da operação de bombeio.

O ponto A na Figura 4.7 indica o momento em que ocorre o curso descendente. Sabe-se a partir da descrição da carta dinamométrica para um padrão de UB funcionando sob condição normal, descrita anteriormente para a Figura 4.5, que no momento do curso descendente a válvula de passeio deveria abrir. Porém, na condição de pancada de fluido, devido a pouca quantidade de fluido na camisa, a pressão existente não é suficiente para abertura da mesma e por isso o curso descendente ocorre com a válvula de passeio fechada. A válvula de passeio só é aberta após a colisão da bomba de fundo com o fluido existente no interior da coluna.

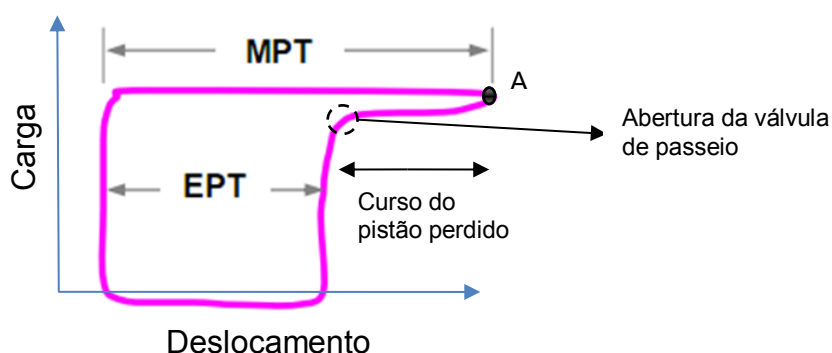


Figura 4.7: Carta dinamométrica associada à condição de pancada de fluido.

Fonte: oilproduction.net (adaptado pelo autor).

4.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foi visto de modo sucinto o método de elevação artificial por BM. Foi abordado que o diagnóstico de poços terrestres que utilizam tal método é feito por meio da CDF, e que para poços rasos a CDF pode ser aproximada pela CDS.

Embora em poços reais o BM esteja sujeito a diferentes condições de bombeio, neste capítulo e nos problemas de identificação tratados nesta dissertação, foram abordadas apenas duas condições: a normal e a de pancada de fluido. Tais condições de bombeio representam grande parte das condições de bombeio encontradas em campo, e por isso foram escolhidas para serem tratadas nesta dissertação.

Ressalta-se que a descrição sucinta do BM realizada neste capítulo deve-se ao fato de que o foco deste trabalho é a identificação caixa-preta de sistemas dinâmicos, por isso, para descrições conceituais detalhadas, bem como diversas abordagens de modelagem fenomenológica para o BM, recomenda-se a leitura: dos artigos de Gibbs (1963), Gibbs e Neely (1966), Doty e Schmidt (1983), Lekia e Evans (1991), Miska, Sharaki e Rajtar (1997), Hojjati e Lukasiewicz (2005); dos livros de Bradley (1992), Takacs (2002) e Cook e Graham (2003); das dissertações de mestrado de Barreto Filho (1993), Nascimento (2005) e Ordoñez (2008).

No próximo capítulo é apresentado o conjunto experimental usado para a coleta dos dados, e em seguida as etapas iniciais do ciclo de identificação são aplicadas. Tais etapas envolvem o planejamento de experimento, a seleção dos sinais de entrada e pré-processamento.

5 MATERIAIS E MÉTODOS

O objetivo deste capítulo é apresentar o conjunto experimental utilizado na coleta de dados, bem como aplicar partes do ciclo de identificação descrito no capítulo 3. Mais especificamente, na seção 5.1 o aparato experimental usado para a realização dos experimentos e coleta de dados é descrito. Na seção 5.2, o planejamento do experimento é aplicado. Na seção 5.3 é realizada a triagem dos dados que serão escolhidos para a identificação de sistemas. O pré-processamento dos dados é realizado na Seção 5.4. A identificação propriamente dita para a geração da carta dinamométrica de superfície (CDS) é realizada no Capítulo 6, assim como a validação e discussão dos resultados.

5.1 CONJUNTO EXPERIMENTAL

Os dados utilizados para a identificação de sistemas foram coletados no laboratório de elevação artificial (LEA), localizado na Escola Politécnica da Universidade Federal da Bahia. Este laboratório possui, basicamente, uma unidade de bombeio, um poço desenvolvido para testes e um sistema SCADA (do inglês *supervisory control and data acquisition* - sistema de supervisão, controle, aquisição de dados), os quais são descritos a seguir.

5.1.1 O poço e o sistema de bombeio mecânico

O poço do LEA (Figura 5.1) foi construído de modo que fosse possível simular condições reais de operação. As características do poço, coluna de hastes e fluido, em operação normal, são: 32 metros de profundidade, com fundo visível e acessível; revestimento: 6,35 cm (2,5 pol.); coluna do tubo de produção: 8,89 cm (3½ pol.); bomba de fundo: 4,45 cm (1¾ pol.); número de hastes: 5 hastes, sendo 3 de 1,5875 cm (5/8 pol.) com 7,62 m (25 pés) de comprimento cada, e 2 de seções curtas, sendo uma de 0,61 m (2 pés) e outra de 3 m (9,84 pés); haste polida: 3,175 cm (1¼ pol.); e curso de operação: 60,96 cm (24 pol.). O fluido contido no poço possui massa específica de 848 kg/m³.



Figura 5.1: Poço desenvolvido para testes.

A unidade de bombeio utilizada (Figura 5.2) é a API 25-67-36, com curso de operação de 24 polegadas, podendo operar até 12 ciclos por minutos (CPM). A Tabela 5.1 mostra as especificações do motor usado como força primária na unidade de bombeio.



Figura 5.2: Unidade de bombeio instalada na Escola Politécnica da Universidade Federal da Bahia.

Tabela 5.1: Especificações do motor de indução rotor tipo gaiola

Potência (/W)	3728,5
Rotação Nominal (/RPM)	1160
Frequência (/Hz)	60
Número de Pólos	6
Fator de potência (cos φ)	0,75
Tensão Nominal (/V)	380
Corrente Nominal (/A)	8,86
Ip/In	6,8
Fator de Serviço	1,15
Conjugado de Partida	200 %
Conjugado máximo	240 %

Fonte: WEG (adaptado pelo autor)

onde o termo I_p/I_n descrito na Tabela 5.1 é a relação entre corrente de partida e a corrente nominal. Ainda usando a Tabela 5.1, com base nas equações do motor de indução¹⁰ (equação (5.1) e (5.2)), pode-se obter outros dados do motor a fim de complementar as informações fornecidas pela Tabela 5.1:

$$N_s = \frac{120 \times freq}{6} = \frac{120 \times 60}{6} = 1200 \text{ RPM} \quad (5.1)$$

$$S_m = \frac{N_s - N_a}{N_s} \times 100 = \frac{1200 - 1160}{1200} \times 100 = 3,33\% \quad (5.2)$$

onde N_s é a velocidade síncrona¹¹ (velocidade de campo girante estático) do motor, e $freq$ refere-se à frequência da rede de alimentação. Na equação (5.2), N_a é a velocidade assíncrona¹² (velocidade de rotação do eixo do motor) nominal do motor (ver Tabela 5.1), e S_m refere-se ao escorregamento do motor (Bose, 2002).

O motor foi instalado no campo com o auxílio do autor do presente trabalho.

5.1.2 Célula de carga e o potenciômetro

A Figura 5.3 mostra em detalhe a disposição da célula de carga e do potenciômetro instalados na haste polida. Observa-se que todo o peso do conjunto de hastes, que

¹⁰ Para detalhes sobre as equações e funcionamento do motor de indução trifásico, recomenda-se a leitura do Capítulo 2 do livro de Barnes (2003).

¹¹ A velocidade síncrona do motor é diretamente proporcional a tensão de alimentação da rede.

¹² A depender da carga mecânica aplicada ao eixo do motor a velocidade assíncrona pode variar.

é sustentado pela haste polida, passa por dentro da célula de carga, e que o potenciômetro é instalado de forma a medir a posição da haste polida da unidade.



Figura 5.3: Detalhe para a disposição da célula de carga e do potenciômetro instalados na haste polida.

As células de carga são transdutores de força. Seu princípio de funcionamento se baseia na variação de resistência elétrica sofrida por sensores denominados extensômetros (no inglês, *strain gages*), quando este é deformado. Os extensômetros são ligados em Ponte da *Wheatstone*. O Quadro 5.1 mostra as especificações da célula de carga acoplada a haste polida, e vista na Figura 5.3.

Quadro 5.1 Especificações da célula de carga usada na UB

Capacidade Nominal (/kg)	1000
Material	Aço inox
Sensibilidade (/mV)	2,000(0,002)
Erro combinado - % saída nominal	< 0,03
Creep à capacidade nominal - % saída nominal	20 min: < 0,03 08 h: < 0,05
Temperatura de trabalho útil (°C)	-5 a +60
Temperatura de trabalho compensada (°C)	+0 a +50
Máx. sobrecarga s/ alterações - % cap. nominal	150
Sobrecarga de ruptura - % cap. nominal	300
Resistência elétrica entrada (/Ω)	400(4)
Resistência elétrica saída (/Ω)	350,0(3,5)
Deflexão máxima, a capacidade nominal (/mm)	< 0,3
Grau de proteção (IEC 529)	IP67

onde o fenômeno de "fluência" ou *creep*, descrito no Quadro 5.1, consiste na variação da deformação ao longo do tempo após a aplicação da carga. Sendo a variação causada devido a escorregamentos entre as faces da estrutura cristalina do aço inoxidável. Este fenômeno apresenta variações aparentes na intensidade da força aplicada ao sensor, mesmo quando não ha incrementos na mesma.

O potenciômetro é um dispositivo elétrico que possui resistência elétrica ajustável. Ele é normalmente confeccionado com substrato em fio e carvão condutivo. Uma diferença de potencial elétrico foi aplicada ao potenciômetro, conectando a fonte de tensão aos terminais extremos deste, e a posição da haste polida foi lida tomando-se a variação de tensão entre o terminal central do potenciômetro e uma das outras extremidades. O Quadro 5.2 mostra as características do potenciômetro usado no experimento.

Quadro 5.2 Especificações do potenciômetro multivoltas usado na UB

Número máximo de voltas	10
Diâmetro do corpo	22 mm
Resistência padrão	100 k Ω
Incerteza-padrão	5 k Ω
Temperatura de operação	-40 °C a +125 °C
Potência a 40 °C	2 W
Potência a 125 °C	0 W
Taxa de ruído máximo (ENR)	100 Ω

5.1.3 Configuração do hardware

A Figura 5.4 (a) mostra a configuração do hardware utilizado na aquisição da posição e carga. Um transdutor de posição converte a posição da haste de bombeio em corrente elétrica, em uma escala de (4 a 20) mA. A corrente elétrica é então adquirida pelo controlador lógico programável (CLP), que a transforma (de modo proporcional) em valores de posição, e por sua vez comunica com o servidor OPC¹³ por meio do protocolo TCP/IP. Finalmente, os dados são transferidos do servidor OPC via conectividade OPC, para serem amostrados pelo software Matlab®.

¹³ OPC (*Open Productivity and Connectivity* ou *OLE for Process Control*) se refere a uma série de padrões e especificações de comunicação, transferência e armazenamento de dados, em formato não proprietário. Para mais detalhes sobre o OPC, recomenda-se uma visita ao sítio <http://www.opcfoundation.org/>.

A Figura 5.4 (a) mostra como a corrente de torque foi adquirida. No caso, o inversor de frequência controla a velocidade do motor e ao mesmo tempo envia as informações referentes ao controle do motor (como corrente de torque, corrente de saída, tensão AC, tensão DC no barramento do inversor, dentre outras) para o CLP por meio da rede industrial DeviceNet¹⁴; que por sua vez se comunica com o servidor OPC por meio do protocolo TCP/IP, e posteriormente é amostrado pelo *software* Matlab.

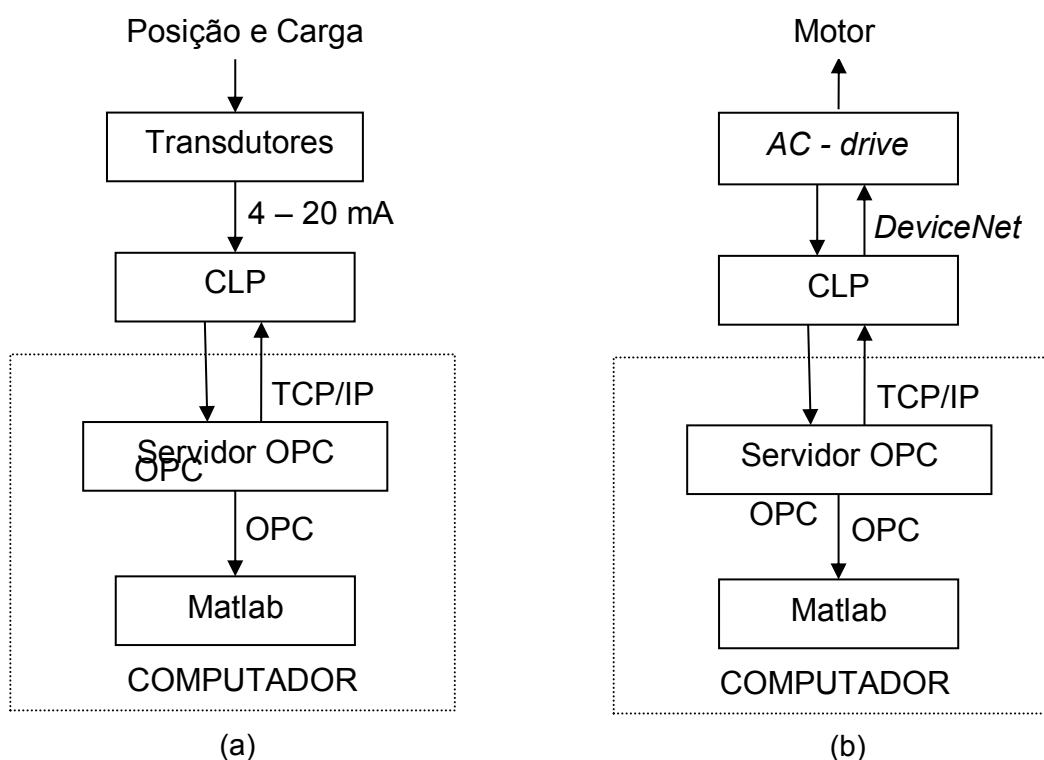


Figura 5.4: Configuração de hardware. Sistema de aquisição de posição e carga (a), e corrente (b).

5.2 PLANEJAMENTO DE EXPERIMENTO PARA AQUISIÇÃO DE DADOS

A Figura 5.5 mostra como o planejamento do experimento, tratado na seção 3.1.1, foi aplicado para aquisição de dados da UB. Embora o planejamento do experimento seja parte integrante da identificação de sistemas, neste capítulo ele foi separado desta a fim de facilitar a visualização e a compreensão do texto, e é discutido a

¹⁴ DeviceNet é um sistema de rede usada na indústria de automação para interligar dispositivos de controle para troca de dados. A rede DeviceNet foi desenvolvida pela Bosch em 1980 e possui metodologia de acesso ao meio físico (MAC – controle de acesso ao meio) dado pelo protocolo CAN (*Controller Area Network*).

seguir.

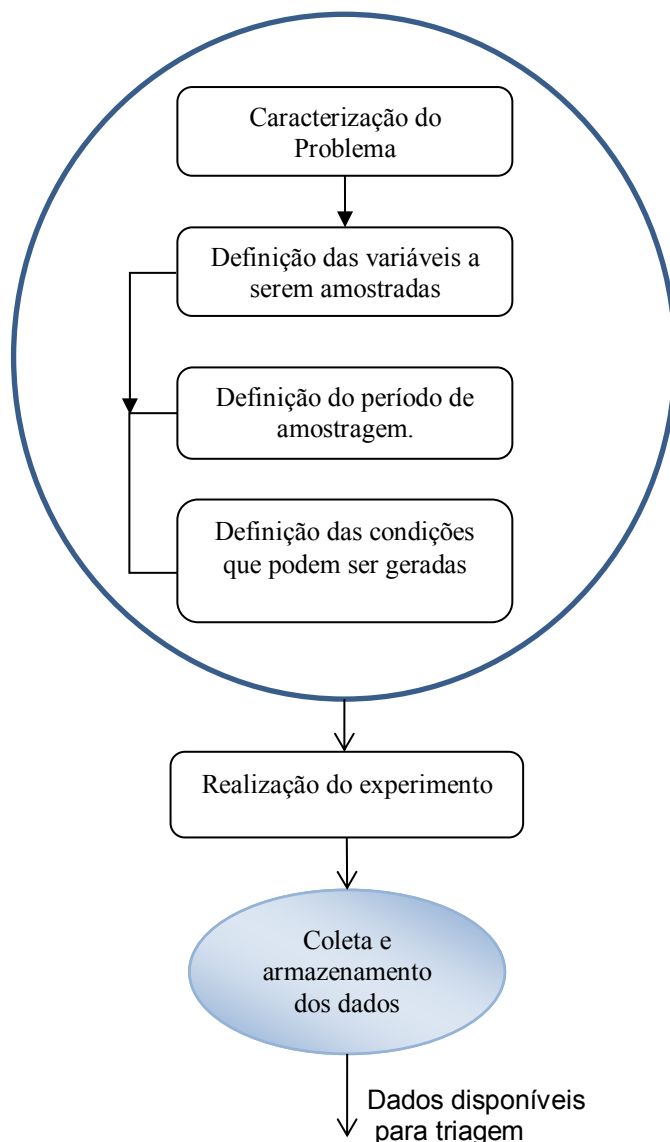


Figura 5.5: Etapas de planejamento de experimento.

Caracterização do problema

Coleta de dados do BM, para serem usados na identificação caixa-preta de sistemas *off-line* com o objetivo de gerar a CDS.

Definição das variáveis a serem amostradas

Como a CDS é um traçado de posição e carga dinâmica suportada pela haste polida ao longo de um curso completo, automaticamente tais variáveis foram escolhidas como saída do sistema a ser identificado.

Foi visto na seção 2.1.2 que o sinal a ser usado como entrada na identificação de sistemas precisa ter relação com o sinal de saída para que a modelagem faça sentido, portanto, usar como entrada na identificação de sistemas algumas das variáveis elétricas necessárias para o acionamento do motor AC é uma opção a ser considerada.

De um modo semelhante ao motor DC, o torque de saída do motor AC depende do produto da densidade de fluxo de entreferro (Φ) e da corrente de rotor (I_R),

$$T \propto \Phi I_R \quad (5.3)$$

onde T é dado em Newton-metro. A corrente I_R , que produz o torque do rotor, a qual é também chamada de corrente de torque, depende da carga mecânica da máquina e é também proporcional ao escorregamento (ver equação 5.4). Quando o motor está funcionando a vazio (sem carga), a rotação assíncrona é quase igual à rotação síncrona, sendo assim, o escorregamento é pequeno, e conseqüentemente a corrente I_R também é pequena, como ilustra a Figura 5.6 (a). Quando o escorregamento no motor aumenta, I_R também aumenta de modo proporcional, como mostra a Figura 5.6 (b).

$$I_R = K \frac{N_s - N_a}{N_s} \quad (5.4)$$




Figura 5.6: Vetores de corrente para condições de baixa carga (a), e alta carga (b).

Ainda com relação à Figura 5.6, observa-se que a corrente de magnetização I_M é independente da carga aplicada ao eixo do motor, já que sua amplitude não varia com a carga. Nota-se que a amplitude de I_M depende unicamente da tensão no estator e da sua frequência; e que o torque produzido no motor é proporcional ao produto vetorial de I_M com I_R . As Figuras 5.6 (a) e (b) foram obtidas a partir do circuito equivalente do modelo simplificado do motor, mostrado na Figura 5.7, de onde se tem que a corrente entregue ao estator é decomposta em I_M e I_R :

$$I_S = \sqrt{I_M^2 + I_R^2} \quad (5.5)$$




Figura 5.7: Circuito simplificado equivalente em condição de estado estacionário de um motor de indução. Onde, V é a tensão de alimentação do estator, X_M é a indutância de magnetização.

A equação (5.6) evidencia o relacionamento entre I_M , a tensão de alimentação do estator (V) e da frequência fornecida ao estator ($freq$)

$$I_M = k \left(\frac{V}{freq} \right) \quad (5.6)$$

onde para manter I_M constante o inversor de frequência varia a tensão proporcionalmente com a variação da frequência de alimentação. Sendo assim, pode-se esperar que o sinal V seja um candidato interessante à entrada na identificação de sistemas.

Como ao longo do curso da haste de bombeio o torque e a velocidade do motor estão continuamente mudando à medida que este reage à carga dinâmica (GIBBS, 1963), é natural esperar que tais mudanças possam ser abstraídas com maior ou menor intensidade¹⁵ de I_R , I_S e V . Por outro lado, como em tese I_M não tem relacionamento com a carga aplicada ao eixo do motor, apenas com a tensão de alimentação do estator e a sua frequência, tal variável não está entre as mais adequadas para ser usada como entrada para identificação da carga. Sendo assim, já que o inversor de frequência consegue distinguir claramente I_M de I_S , os sinais escolhidos como candidatos a entrada dos sistemas a serem identificados são: I_R , I_S e V .

Para uma compreensão detalhada sobre a modelagem fenomenológica do motor de indução trifásico, recomenda-se a leitura dos livros: Bose (2002) e Barnes (2003).

Definição do Período de Amostragem e do tamanho da amostra

Usando um dinamômetro acoplado à haste polida, tem-se o registro contínuo de CDS. Deste modo, as condições para obtenção de uma CDS de boa qualidade dependem da escolha adequada do tambor, do dinamômetro e do tipo de mola (Barreto, 2002). Por outro lado, ao trabalhar com sistemas digitais, que é o caso deste trabalho, faz-se necessário que os sinais de corrente que transmitem o equivalente em posição e carga sejam convertidos para a forma digital. De acordo com especialistas, 100 pontos de amostra de posição e de carga durante um ciclo completo da UB são suficientes para desenhar adequadamente a carta dinamométrica (Bezerra, 2010). Deste modo, pode-se também deduzir que será possível realizar a identificação usando ao menos 100 pontos de amostra para as variáveis de entrada e saída. Sendo assim, o cálculo do período (e frequência) de amostragem foi realizado do seguinte modo:

$$T_s = \frac{60 / \max(CPM)}{100} \quad (5.7)$$

onde $\max(CPM)$ refere-se ao máximo CPM suportado pelo BM; a constante 60

¹⁵ Esta avaliação de relacionamento será feita na fase de “Triagem/Escolha” do sinal de entrada, como discutido na seção 2.1.2.

refere-se a quantidade de segundos contida em 1 minuto; a divisão $60/\max(CPM)$ refere-se à quantidade de segundos necessária para a unidade de bombeio realizar um ciclo. Como para o BM do LEA o $\max(CPM) = 12$, então, substituindo este valor na equação 5.7, tem-se:

$$T_s = \frac{60/\max(12)}{100} = 0,05 \text{ segundos}$$

e, fazendo $f_s = (0,05)^{-1} = 20 \text{ Hz}$, tem-se a frequência da amostragem.

Por sua vez, tem-se que o tamanho da amostra (N) depende de dois fatores: do tempo para realização do experimento e do período de amostragem. O tempo para realização do experimento depende dos padrões de CDS a serem gerados em um único experimento.

Definição dos Padrões de Carta Dinamométrica que podem ser Simulados no LEA

Para o presente trabalho decidiu-se simular as condições de bombeio normal e pancada de fluido. Tais condições foram escolhidas por, de acordo com especialistas, ocorrerem com maior frequência em poços de petróleo que possuem o BM.

Realização do Experimento e Coleta dos dados

As condições de operação listadas no tópico anterior, de bombeamento normal e pancada de fluido, foram obtidas em um mesmo experimento. A Figura 5.8 (a) exemplifica como o nível do poço variou durante a realização do experimento. No caso, o experimento foi iniciado com o nível dinâmico do anular a uma altura de aproximadamente 11 metros; logo em seguida, uma válvula responsável pelo suprimento de fluido do reservatório ao poço foi fechada; a partir daí, à medida que a bomba elevava o fluido contido no poço, o anular do poço ia se esvaziando (o nível diminuindo), até chegar à condição de pancada de fluido. Ao todo durante este experimento foram adquiridos 34250 dados das variáveis previamente selecionadas, totalizando um tempo de coleta de aproximadamente 29 minutos. A Figura 5.8 (b) mostra que a velocidade de bombeio do BM, a qual é dada em COM, foi manipulada durante a realização do experimento.




Figura 5.8: Nível do anular (a), e variação de CPM da UB (b).

As Figuras 5.9 (a) e (b) mostram, respectivamente, uma janela de tempo contendo 2000 amostras de dados de posição e carga na haste polida. Para a carga se observa que tanto a amplitude quanto o período¹⁶ variam com o passar do tempo. Para a posição observa-se que a amplitude é aproximadamente constante, e que apenas o período do sinal varia.

¹⁶ Basicamente devido à manipulação do CPM.




Figura 5.9: Janela de 100 segundos de dados amostrados de posição (a), e carga (b) da haste polida.

As cartas dinamométrica registradas durante todo o experimento, as quais totalizam aproximadamente 280 cartas, são mostradas na Figura 5.10.

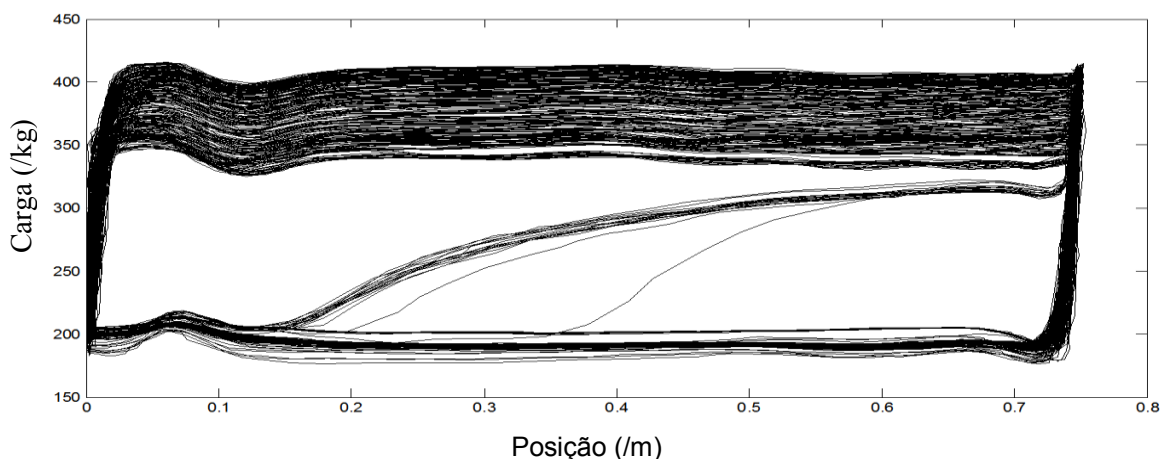


Figura 5.10: Cartas dinamométricas registradas por um período de aproximadamente 30 minutos.

A Figura 5.11 mostra uma janela¹⁷ de 2000 amostras de dados de tensão de saída do inversor.




Figura 5.11: Janela de 100 s de dados de tensão de saída do inversor.

As Figuras 5.12 (a) e (b) mostram, respectivamente, uma janela de 2000 dados coletados de corrente produtora de torque e corrente de saída do inversor (corrente no estator).

¹⁷ Devido à taxa de amostragem escolhida e a duração do experimento, para que fosse possível enxergar de modo claro os sinais amostrados, optou-se em mostrar na Figura 5.11, assim como em algumas outras situações neste trabalho, apenas uma janela de dados.

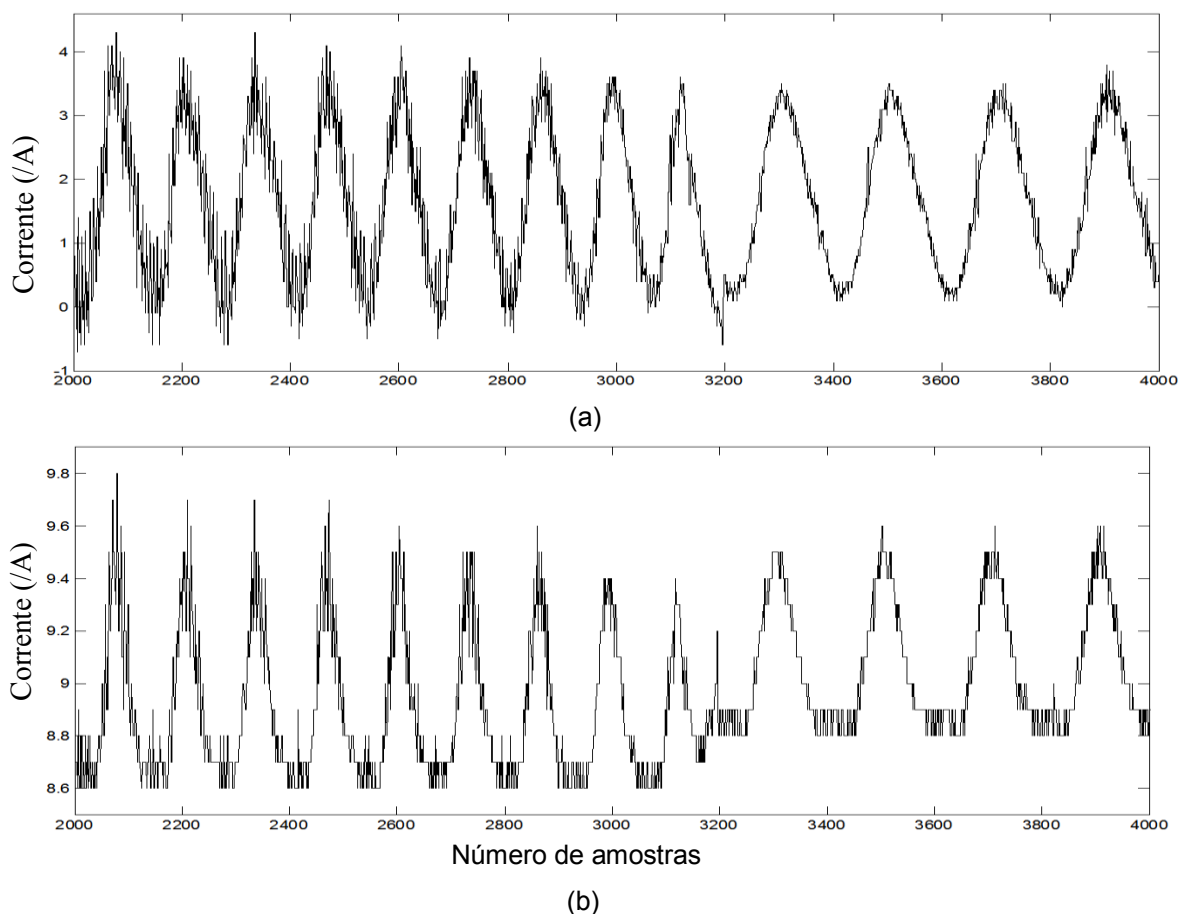


Figura 5.12: Janela de 100 segundos de dados de corrente de torque (a), e corrente de saída do inversor (b).

5.3 APLICAÇÕES DO CICLO DE IDENTIFICAÇÃO PÓS-PLANEJAMENTO DE EXPERIMENTO

Após o planejamento do experimento para a coleta de dados, como descrito na Seção 5.5, os próximos passos do ciclo de identificação de sistemas seguem a metodologia para identificação dada na Figura 5.13, cujos conceitos já foram tratados no Capítulo 3. Uma variação desta metodologia foi usada com sucesso por Cajueiro, Kalid e Leizer (2012 e 2011(a), (b), (c)) para o problema de identificação da posição da haste de bombeio mecânico usando variáveis elétricas do motor como entrada, e também para o problema de identificação do nível no anular, o qual possuía como entrada a corrente de torque. Os procedimentos da Figura 5.13 consistem na preparação dos dados para estimação e validação. Estes são tratados para a posição e a carga suportada pela haste polida no decorrer das próximas seções.

Como a identificação de sistemas é um processo iterativo, algumas etapas da Figura 5.13 são realizadas quase que simultaneamente.

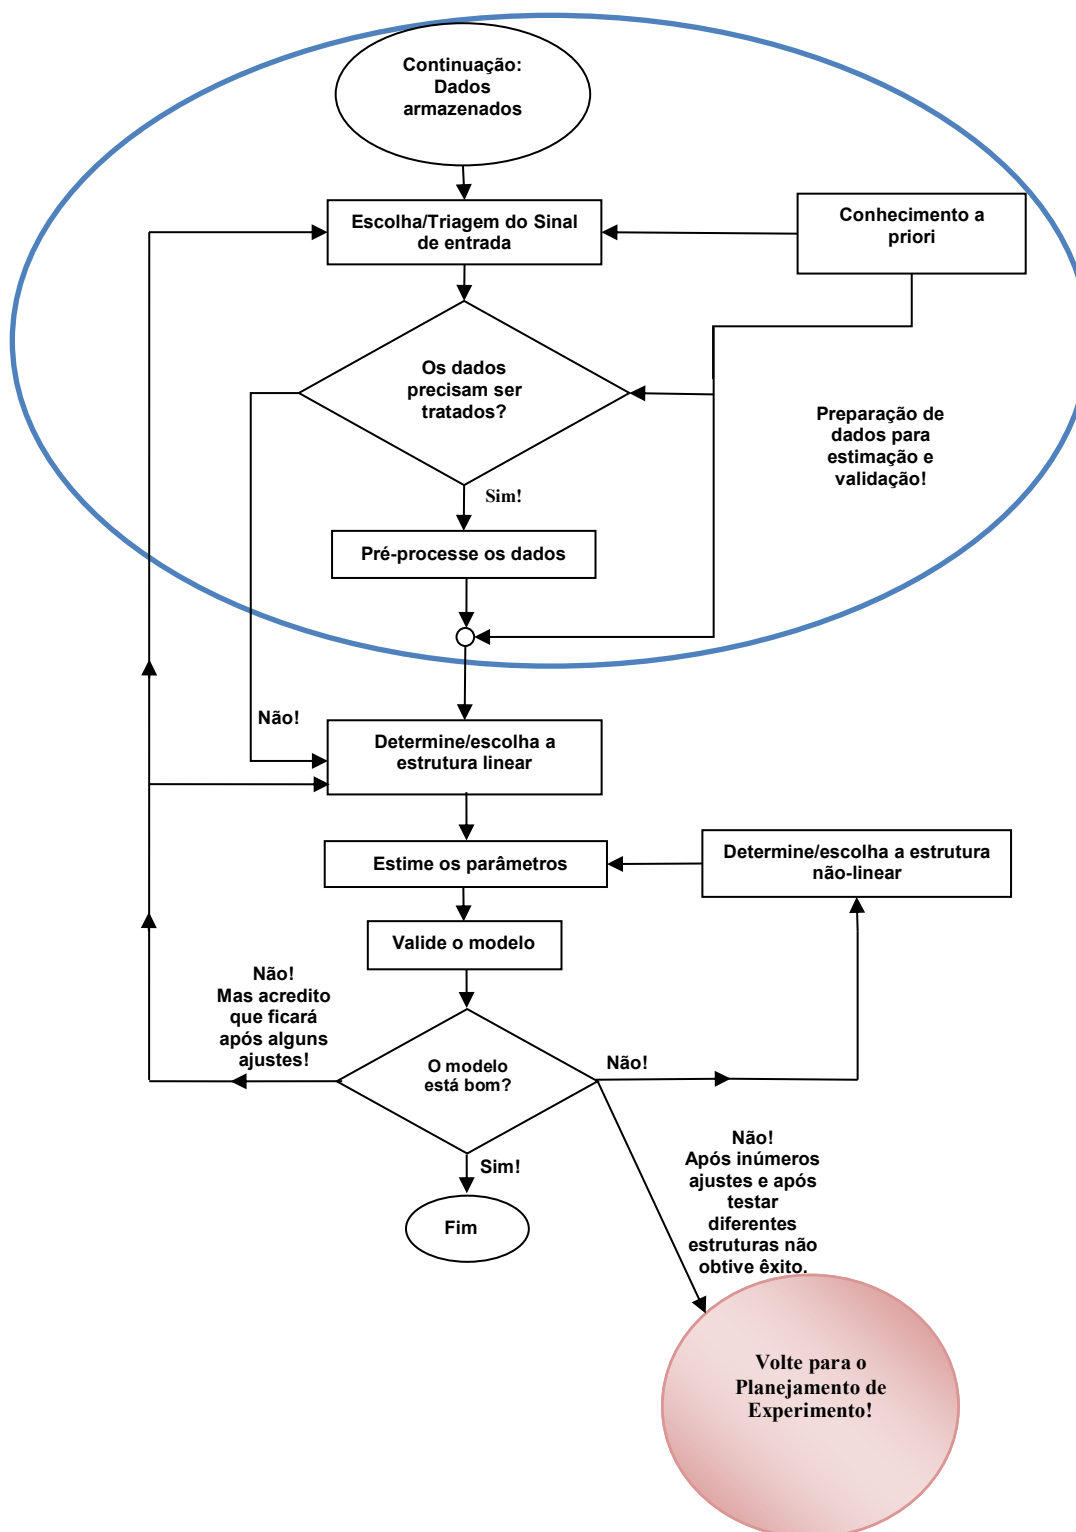


Figura 5.13: Ciclo de identificação de sistemas.

5.3.1 Triagem/Escolha do Sinal de Entrada

A *função de correlação cruzada (FCC)*, vista na seção 2.1.2, foi usada a fim de ajudar na escolha da variável a ser utilizada como entrada na identificação de sistemas. A Figura 5.14 mostra o resultado do cálculo da FCC entre cada uma das funções candidatas a entrada, descritas na seção 5.2, e a posição da haste polida (saída do sistema). A partir de tais funções verificou-se que as três possuem correlação com a posição da haste polida, já que o resultado da FCC está próximo de 1 para determinados instantes de tempo. Vale lembrar que o cálculo da FCC é realizado em cada instante em que uma função é deslocada sobre outra função. Para os cálculos da FCC mostrados na Figura 5.14 observa-se que o ponto de maior correlação ocorre aproximadamente entre 20 e 40 atrasos de tempo.

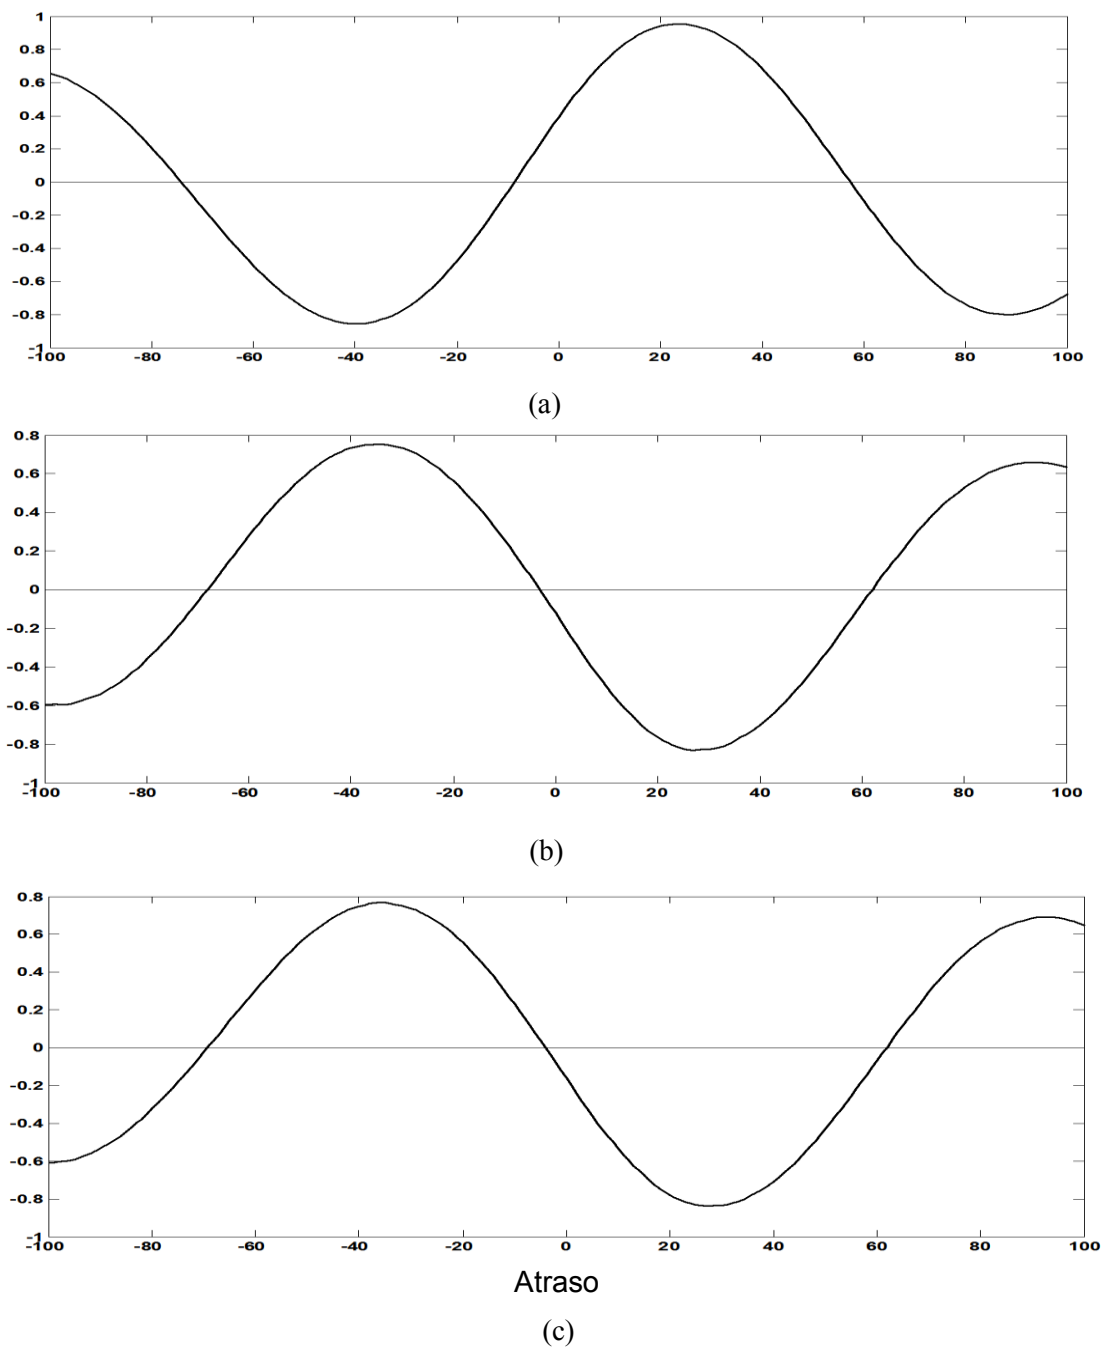


Figura 5.14: Triagem do sinal de entrada para a identificação do sistema que envolve a posição da haste polida. Funções de correlação cruzada entre a tensão de saída do inversor e posição da haste polida (a), entre a corrente de saída do inversor e a posição da haste polida (b), e entre a corrente de torque e a posição da haste polida (c).

O próximo objetivo é descobrir se estas três variáveis se qualificam como entrada ou se há uma redundância entre elas. A indicação de correlação entre duas destas variáveis sugere que apenas uma delas será usada como entrada do modelo a ser identificado. O resultado de correlação cruzada realizado entre tais variáveis é mostrado na Figura 5.15.




Figura 5.15: Triagem do sinal de entrada para a identificação do sistema que envolve a posição da haste polida. Funções de correlação cruzada entre a corrente e a tensão de saída do inversor (a), entre a corrente de torque e a tensão de saída do inversor (b), e entre a corrente de torque e a corrente de saída do inversor (c).

Observa-se na Figura 5.15 que os sinais candidatos à entrada estão fortemente correlacionados e, portanto, apenas um destes será escolhido para a identificação da posição. Tal resultado está de acordo com a discussão realizada na seção 5.2., no tópico “Definição das variáveis a serem amostradas”, e direciona este trabalho à identificação SISO (*single input and single output*, do inglês: única entrada-única saída).

Como a corrente entregue ao estator (I_S) do motor pode ser medida diretamente, o que não acontece com a corrente produtora de torque (I_R) como mostra a equação (5.5), neste trabalho escolheu-se utilizar I_S para identificação da posição. No entanto, ressalta-se que o resultado da identificação para ambas as variáveis são praticamente iguais, como pode ser visto nos trabalhos de Cajueiro, Kalid e Leizer (2011(b)) e (2012), uma vez que o grau de relação entre I_S e I_R , e a posição da haste polida são similares. Outra opção interessante seria a escolha da tensão V (equação 5.6) entregue pelo inversor de frequência ao motor. No entanto, como a corrente de saída do inversor já atende às necessidades para identificação da posição, haja vista que esta foi usada com sucesso anteriormente em alguns dos trabalhos citados neste parágrafo, a tensão V não foi escolhida.

Com relação à **carga** atuante na haste polida, os resultados dos cálculos da FCC entre as variáveis candidatas à entrada do sistema de identificação e entre a **carga** (saída do sistema de identificação) são mostrados na Figura 5.16. A partir de tais gráficos verificou-se a existência de correlação significativa entre cada uma das três candidatas a entrada e a saída do sistema, já que o resultado da FCC se encontra próximo de 1. Deste modo, como as variáveis candidatas a entrada do sistema a ser identificado estão correlacionadas, faz sentido que seja usado um sistema SISO. Sendo assim, a corrente de saída do inversor foi escolhida como a variável de entrada.

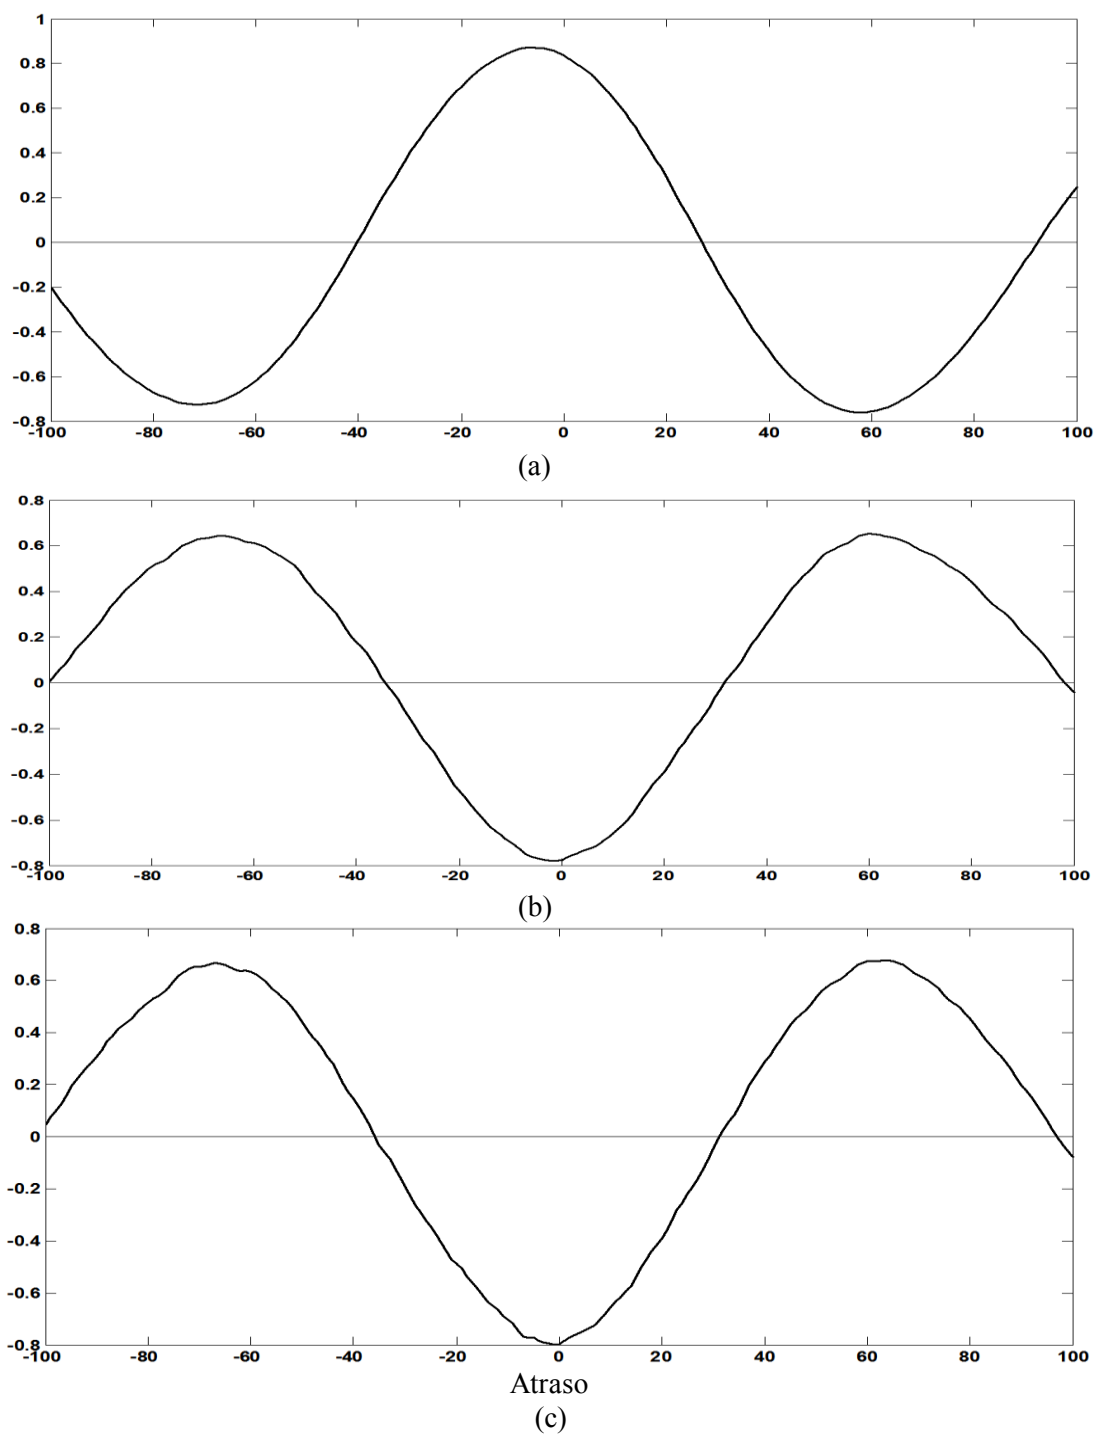


Figura 5.16: Triagem do sinal de entrada para a identificação do sistema que envolve a carga na haste polida. Funções de correlação cruzada entre a tensão de saída do inversor e a carga atuante na haste polida (a), entre a corrente de saída do inversor e a carga atuante na haste polida (b), e entre a corrente de torque e a carga atuante na haste polida (c).

5.4 PRÉ-PROCESSAMENTO DOS DADOS

A. Filtragem dos dados

Como para o experimento em questão a máxima velocidade imposta à unidade de bombeio foi de 10 CPM, tem-se que a máxima frequência que o sistema pode alcançar é 0,16 Hz, pois:

$$f = \frac{1}{60/10} = 0,16 \text{ Hz} \quad (5.8)$$

A fim de investigar as propriedades do sinal de posição da haste polida (aqui chamado de y_{posi}) em termos de componentes de frequência, aplicou-se a este a transformada rápida de Fourier (FFT) e observou-se que este não está corrompido com ruído de potência espectral relevante, como mostra a Figura 5.17.




Figura 5.17: Espectro de amplitude de lado único do sinal de posição.

Aplicando a FFT ao sinal de corrente de saída do inversor (sinal de entrada da identificação, aqui chamado de u), observou-se que este sinal possui um espectro rico em harmônicos, bem como ruído branco de baixa potência adicionado (ver Figura 5.18). Por tanto, a fim de adequar este sinal para a identificação de sistemas, uma vez que harmônicos e ruídos são desinteressantes para esta identificação, um filtro elíptico digital passa-baixas de primeira ordem foi projetado:

$$H(z) = \frac{0,084817 z + 0,084817}{z - 0,83037}. \quad (5.9)$$

Este mesmo filtro foi também aplicado ao sinal de posição, a fim de manter as possíveis relações lineares.




Figura 5.18: Espectro de amplitude de lado único do sinal de corrente de saída do inversor.

Observa-se na Figura 5.19 que para a corrente de saída do inversor o filtro passa-baixas atuou como um conversor D/A (digital/analógico), suavizando o sinal modulado de corrente. Para este caso a conversão D/A é essencial no processo de identificação, já que a alta frequência do trem de pulsos dada pela modulação por largura de pulso¹⁸ (PWM) aumenta o erro na estimação dos parâmetros do modelo.

¹⁸ O leitor interessado em compreender como funciona a modulação PWM deve-se reportar ao livro de Bose (2002).




Figura 5.19: Sinal de corrente de saída do inversor após filtragem (linha contínua em preto), e sem filtragem (linha tracejada em azul).

Para a identificação do sistema SISO que tem como entrada a corrente de saída do inversor, e como saída a carga na haste polida, a aplicação de um filtro passa-baixas ao sinal de carga distorceria o padrão real da carta dinamométrica. Isto porque para condições normais de bombeio o padrão do gráfico da carga na haste se aproxima de uma onda retangular; e como em termos matemáticos, o sinal de uma onda retangular é formado por uma soma de inúmeros harmônicos, a eliminação destes por meio de um filtro passa-baixas suavizaria o sinal de carga, pois eliminaria as descontinuidades.

Como um filtro não pode ser aplicado ao sinal da carga suportada na haste polida carga (saída do sistema), para a identificação de sistemas usando uma estrutura linear (como a ARX) ele também não deve ser aplicado ao sinal de corrente de saída do inversor (entrada do sistema), pois caso isto fosse feito as relações lineares existentes entre os sinais de entrada e saída não poderiam mantidas, como discutido na seção 2.1.3. Por outro lado, caso o resultado da identificação da estrutura linear não seja satisfatório, um dos modelos não-lineares vistos na seção 2.1.5, será considerado, e portanto, a aplicação da equação (5.9) será considerada somente para o sinal de entrada; isto é possível, haja vista que não é esperado significado físico nos parâmetros de modelos caixa-preta não-lineares.

B. Adimensionalização

Ainda prosseguindo no pré-processamento dos sinais, uma operação de adimensionalização é aplicada aos dados de corrente de saída do inversor, posição e carga na haste polida, a fim de melhorar a capacidade dos algoritmos de treinamento, ao mesmo tempo em que torna os modelos identificados robustos para a extrapolação. Para a entrada e para as saídas, a adimensionalização é aplicada do seguinte modo:

$$u_{adim} = \frac{u(k) - \min(u)}{\max(u) - \min(u)}; \quad (5.10)$$

$$y_{posi_{adim}} = \frac{y_{posi}(k) - \min(y_{posi})}{\max(y_{posi}) - \min(y_{posi})}; \quad (5.11)$$

$$y_{carga_{adim}} = \frac{y_{carga}(k) - \min(y_{carga})}{\max(y_{carga}) - \min(y_{carga})}; \quad (5.12)$$

onde os termos min e max referem-se ao valor mínimo e máximo do sinal; u , y_{posi} e y_{carga} são, respectivamente, a corrente de saída do inversor, a posição da haste polida e a carga suportada na haste polida.

C. Separação dos dados em subconjuntos

Como ao todo foram adquiridos 34160 dados para o propósito da estimação e da validação cruzada, os dados coletados foram divididos em subconjuntos do seguinte modo:

- Para a identificação da relação corrente de saída de inversor e posição dinâmica da haste polida, tem-se:

$$Z_{ep} = [u(500), y_1(500), u(501), y_1(501), \dots, u(16500), y_1(16500)];$$

$$Z_{vp} = [u(17001), y_1(17001), u(17002), y_1(17002), \dots, u(30000), y_1(30000)];$$

$$Z_{vp2} = [u(30001), y_1(30001), u(30002), y_1(30002), \dots, u(34250), y_1(34250)];$$

onde $y_1 = y_{posi_{adim}}$ e $u = u_{adim}$ são, respectivamente, o sinal de posição de haste polida e corrente de saída do inversor; Z_{ep} , Z_{vp} e Z_{vp2} referem-se, respectivamente, ao conjunto de dados de estimação, validação e extrapolação. Tais janelas de dados são dadas de acordo com a ordem mencionada na Figura 5.20.

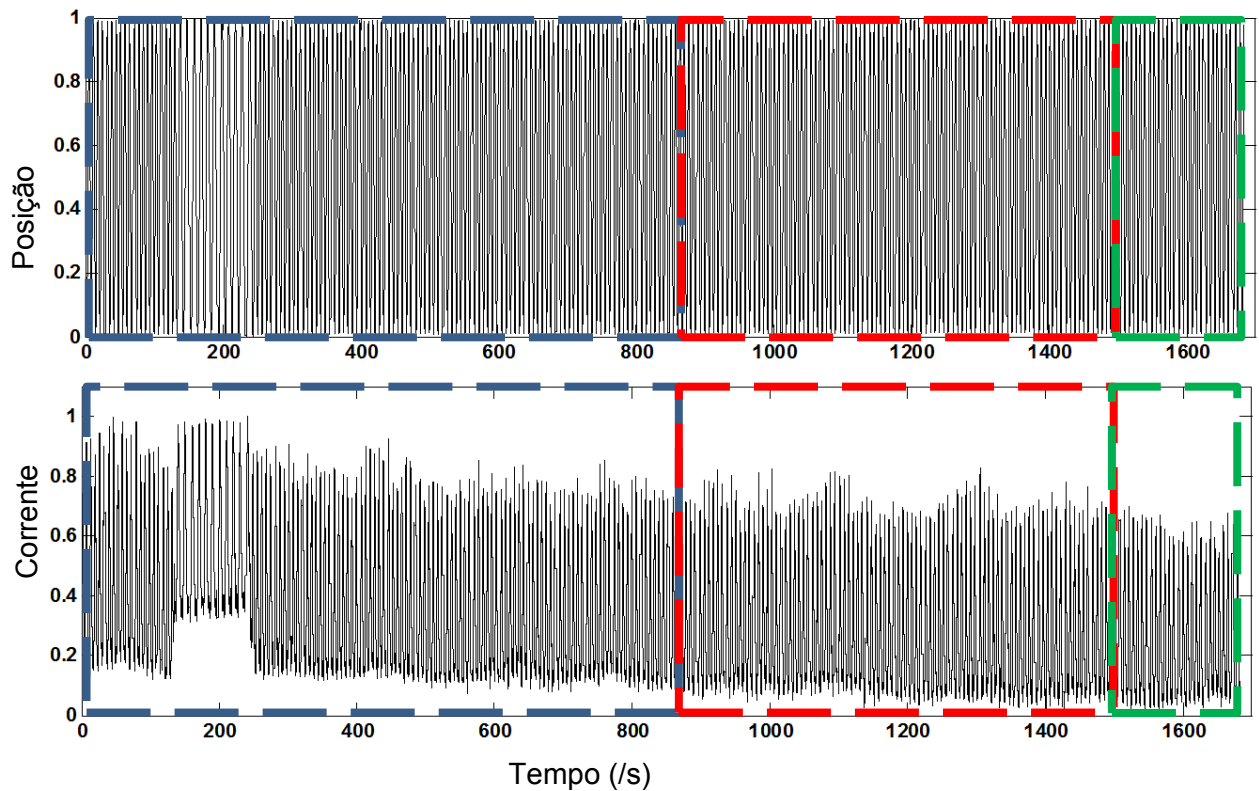


Figura 5.20: Conjunto de dados amostrados de corrente de saída do inversor e posição de haste plida, usados para estimação (janela azul), validação (janela vermelha) e extrapolação (janela verde).

- Para a identificação da relação corrente de saída de inversor e carga dinâmica na haste plida, tem-se:

$$Z_{ec} = [u(500), y_2(500), u(501), y_2(501), \dots, u(16500), y_2(16500)];$$

$$Z_{vc} = [u(17001), y_2(17001), u(17002), y_2(17002), \dots, u(30000), y_2(30000)];$$

$$Z_{vcp} = [u(30001), y_2(30001), u(30002), y_2(30002), \dots, u(34250), y_2(34250)];$$

onde $y_2 = y_{carga_{adim}}$; Z_{ec} , Z_{vc} e Z_{vcp} referem-se, respectivamente, ao conjunto de dados de estimação, validação e extrapolação. Tais janelas de dados são dadas de acordo com a ordem mencionada na Figura 5.21.

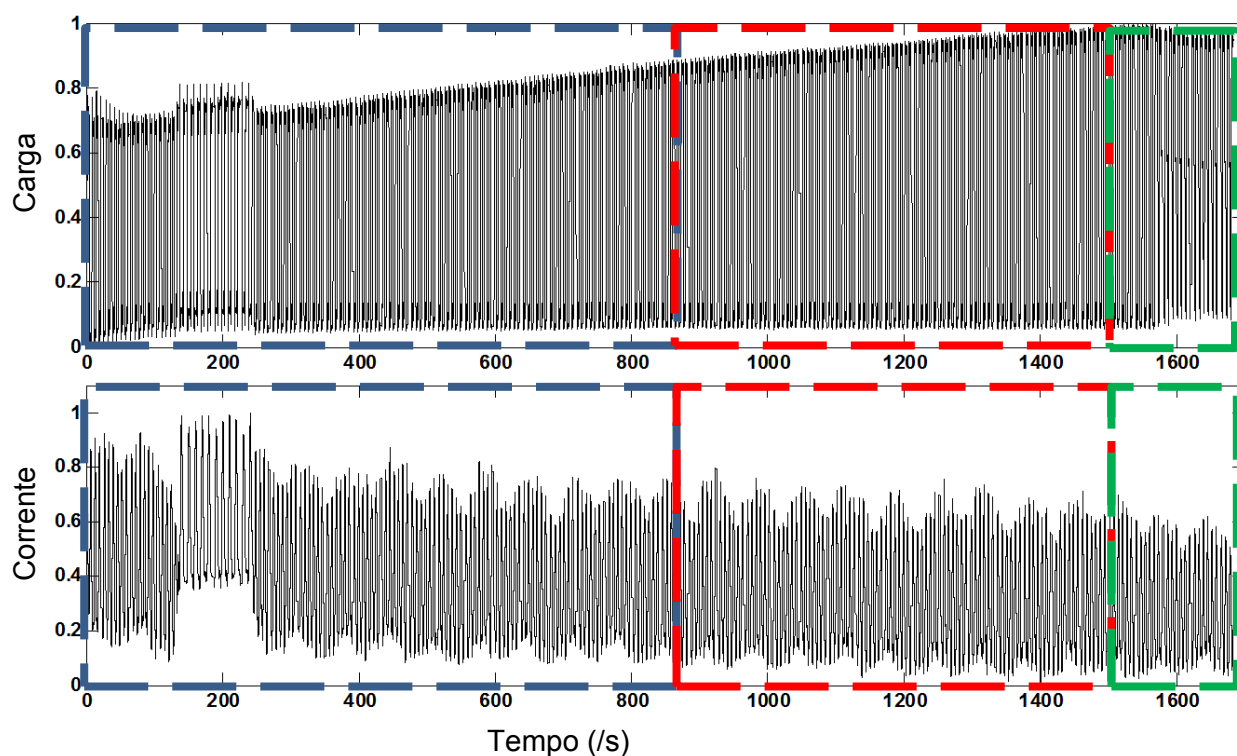


Figura 5.21: Conjunto de dados de corrente de saída do inversor e carga na haste polida, usados para estimação (janela azul), validação (janela vermelha) e extrapolação (janela verde).

Como o experimento cujos dados foram coletados foi realizado de modo dinâmico, haja vista que o nível do anular variou da condição normal até a condição de pancada de fluido; especialmente para a identificação de sistemas que envolve a carga na haste polida, torna-se essencial usar uma grande quantidade de dados de estimação (no caso, 16500 em Zec), pois à medida que o nível no anular diminui, a força do fluido que atua sobre a coluna de hastes no sentido ascendente também diminui, e isto faz com que a haste polida tenha que suportar cada vez mais carga; o que obriga ao modelo a ter que representar tais variações de amplitude.

6 RESULTADOS E DISCUSSÃO

No capítulo 5 o conjunto experimental foi apresentado, o experimento planejado, e os dados foram coletados e tratados. Neste capítulo, mais especificamente na seção 6.1, o modelo SISO que tem a posição da haste polida como saída e a corrente de saída do inversor como entrada é identificado. Na seção 6.2, o modelo SISO que tem a carga suportada pela haste polida como saída e a corrente de saída do inversor como entrada é identificado. Na seção 6.3, a carta dinamométrica é gerada.

6.1 IDENTIFICAÇÃO PARA O SISTEMA: POSIÇÃO DE HASTE POLIDA - CORRENTE DE SAÍDA DO INVERSOR

Como discutido na seção 2.1.4, a identificação de sistemas normalmente é feita usando primeiramente estruturas de modelos mais simples, como as lineares, validando-as a fim de se certificar se tais modelos atendem ou não as necessidades. Apenas, caso o desempenho do modelo linear não seja satisfatório, utiliza-se então a abordagem de identificação não-linear. Sendo assim, nesta dissertação, o modelo ARX é primeiro identificado.

6.1.1 Análise Preliminar: Estimando o modelo linear ARX

a) Determinação do Atraso

A priori, para a determinação do valor “mais adequado” de na e nb , o valor de nk foi fixado em 1.

b) Determinação da Ordem do modelo

O FPE, apresentado na seção 2.1.6, foi escolhido a fim de avaliar a ordem “mais adequada” do modelo ARX (cuja estrutura é descrita na seção 2.1.4.1), estimado a partir do conjunto de dados de estimação z_{ep} .

Como já é conhecido que o valor de $nk = 1$, para a escolha de na gerou-se um gráfico que relaciona o critério FPE com o número de pares do modelo, $na + nb$, do seguinte modo:

```
Para na = 1:10
  Para nb = 1
    Compute FPE
  Fim
Fim
```

Este gráfico permite visualizar a contribuição de na para a minimização do critério FPE, como mostra a Figura 6.1.




Figura 6.1: Desempenho da estimação do modelo ARX pelo critério FPE, mantendo-se $nb=1$ e variando-se na de 1 a 10.

Na Figura 6.1, para $na = 2$, tem-se o valor $FPE = 1,1 \times 10^{-6}$. Como a partir deste ponto as variações descendentes do FPE são muito sucintas, o valor de $na = 2$ foi selecionado.

A mesma estratégia foi usada para escolher o valor de nb , só que agora o valor de na foi fixado no anteriormente escolhido, obtendo-se a Figura 6.2 de acordo com a sequência do programa abaixo:

```
Para na = 2
  Para nb = 1:10
```

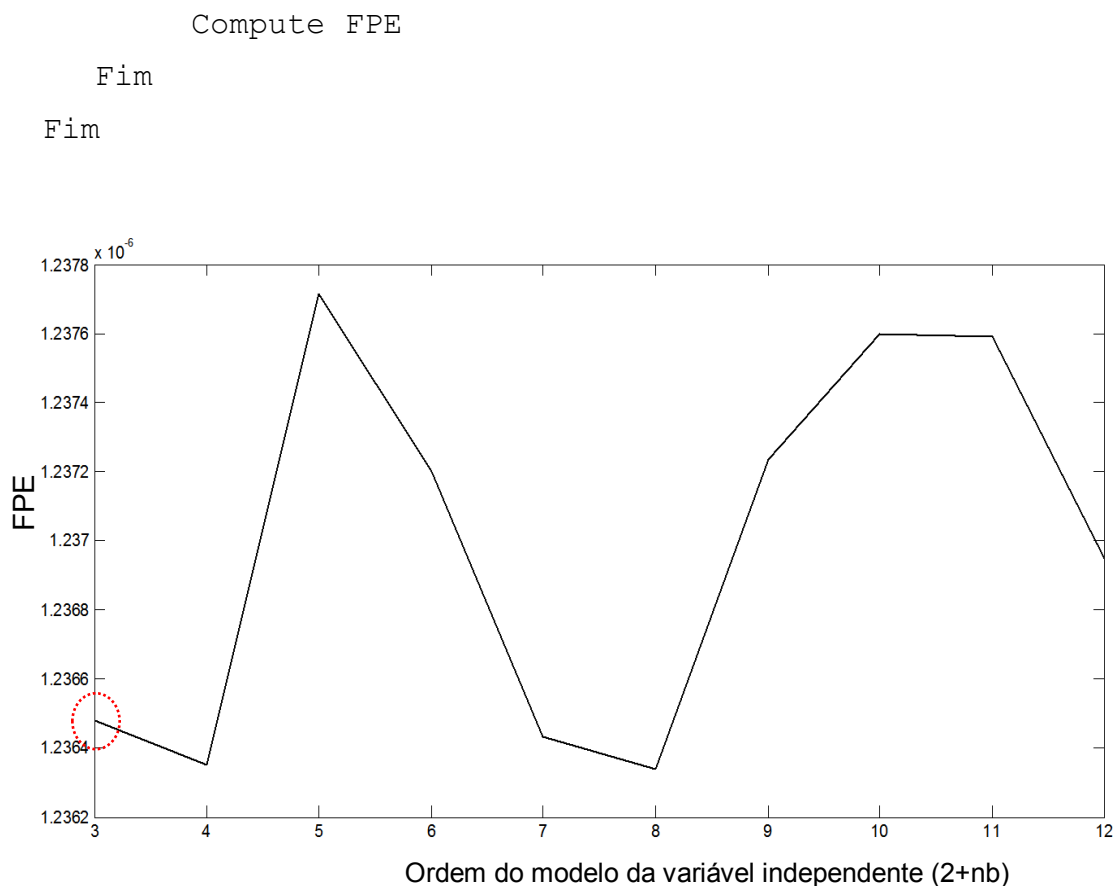


Figura 6.2: Desempenho da estimação do modelo ARX pelo critério FPE, mantendo-se $na=2$ e variando-se nb de 1 a 10.

Como se pode observar na Figura 6.2, o primeiro mínimo ocorre quando $2 + nb = 4$, ou seja, quando $nb = 2$, obtendo-se o $FPE = 1,2 \times 10^{-7}$. A partir de tal ponto, o valor de FPE incrementa até o número de pares $2 + nb = 5$, quando então volta a diminuir. Como o objetivo é escolher a menor ordem que melhor ajuste o modelo aos dados medidos, como a diferença do FPE para $nb = 1$ e $nb = 2$ é pequena, escolheu-se $nb = 1$.

Para a escolha do tempo morto fixou-se na e nb e variou-se nk ; a Figura 6.3 mostra o comportamento do modelo ARX escolhido para diferentes números de atrasos.




Figura 6.3: Desempenho da estimação do modelo ARX com $na=2$ e $nb=1$ pelo critério do FPE em função do número de atrasos (nk).

Observa-se na Figura 6.3 que o menor FPE ocorre para $nk = 1$.

c) Estimação dos Parâmetros e Validação

A estimação do modelo ARX para as ordens selecionadas no tópico anterior, $na = 2$, $nb = 1$ e $nk = 1$, aqui chamado de modelo M1, foi feita pelo método dos mínimos quadrados, o qual foi resolvido pela aplicação da *decomposição QR* (vista na seção 2.1.7). O resultado para a estimação dos parâmetros do modelo M1 e o percentual de ajuste calculado pela equação (2.26) usando-se o conjunto de dados de validação zv são descritos no Quadro 6.1.

Para fins de comparação, ainda no Quadro 6.1 são apresentados os cálculos do FPE e da *validação cruzada* (ajustes) para a estimação dos parâmetros de diferentes ordens, as quais foram sugeridas de modo a explorar ordens próximas a previamente escolhida. O resultado da validação cruzada mostra que os incrementos nas ordens dos modelos não causaram melhorias relevantes em suas estimativas sendo, portanto, o modelo M1 o mais adequado dentre os modelos estimados.

Quadro 6.1: Resultado das estimativas e validação do modelo ARX

	Ordem <i>na, nb, nk</i>	Modelo	FPE	Ajuste (%)
M1	2,1,1	$y_1(k) = 1,984y_1(k-1) - 0,9862y_1(k-2) - 0,0009294u(k-1)$	$1,16 \cdot 10^{-6}$	67,2
M2	2,2,1	$y_1(k) = 1,984y_1(k-1) - 0,9863y_1(k-2) - 0,001543u(k-1) + 0,0006221u(k-2)$	$1,16 \cdot 10^{-6}$	67,3
M3	3,2,1	$y_1(k) = 2,015y_1(k-1) - 1,049y_1(k-2) + 0,03144y_1(k-3) - 0,001511u(k-1) + 0,0005806u(k-2)$	$1,16 \cdot 10^{-6}$	67,8
M4	2,3,1	$y_1(k) = 1,984y_1(k-1) - 0,9864y_1(k-2) - 0,0007442u(k-1) - 0,001485u(k-2) + 0,001328u(k-3)$	$1,16 \cdot 10^{-6}$	67,1
M5	5,5,1	$y_1(k) = 2,131y_1(k-1) - 1,798y_1(k-2) + 1,382y_1(k-3) - 0,9123u(k-4) + 0,1953u(k-5) - 0,002021u(k-1) + 0,001381u(k-2) - 0,001186u(k-3) - 0,001688u(k-4) + 0,002861u(k-5)$	$8,20 \cdot 10^{-7}$	61,9

A Figura 6.4 mostra a uma janela de tempo de saída simulada e saída media. O sinal simulado foi obtido usando o sinal de entrada presente no conjunto de dados de validação *zvp* no modelo estimado M1. Observa-se que embora o modelo M1 tenha conseguido reproduzir de modo aproximado o comportamento em frequência do sinal medido de posição da haste, a Figura 6.4 deixa claro que ele não foi capaz de reproduzir de modo satisfatório o comportamento em amplitude. Isto, no caso de uma simulação da CDS usando tal modelo traria ao especialista uma falsa ideia a respeito do curso do pistão. No caso, o modelo M1 necessitaria ser multiplicado por um ganho, a fim de aproximar a saída simulada da saída medida. O sinal de desvio de simulação da Figura 6.5, o qual foi obtido aplicando a equação (2.27) aos sinais medidos e simulados vistos na Figura 6.4, mostra que a amplitude do sinal de desvio de simulação equivale a aproximadamente 42% da amplitude do sinal medido. Tal comportamento do modelo M1 significa um desvio sistemático. Isso pode ser devido a uma entrada não considerada, a um ruído colorido, ou a não-linearidade do sistema. Optou-se neste trabalho por considerar que esse desvio é devido a não-linearidade e por isso a escolha de modelos não-lineares.




Figura 6.4: Identificação da posição. Comparação entre saída medida (linha em preto) e saída simulada (linha em vermelho) para o modelo M1.




Figura 6.5: Sinal de resíduo para o modelo M1.

Ressalta-se, como dito na seção 2.1.4, que em análises preliminares todos os modelos abordados no Quadro 2.1 foram testados; no entanto, referindo-se a identificação de sistemas dinâmicos lineares, como os resultados mais representativos foram obtidos por meio do modelo ARX, para esta dissertação apenas tal modelo é usado.

6.1.2 Estimando o modelo NARX

a) Estimação dos Parâmetros e Validação

Espera-se que as ordens que trouxeram uma melhor estimativa para o modelo linear ARX proporcionem bons resultados para o modelo NARX. Por tanto, considerando as ordens das melhores estimativas realizadas anteriormente para o modelo ARX (no caso, os modelos M1, M2, M3 e M4), e deixando o GCV (equação 3.23) escolher o melhor conjunto de *wavelets* existentes a partir do conjunto de dados de estimação, ze , os modelos NARX foram estimados e o critério FPE (equação 2.21) foi calculado para cada uma das ordens correspondentes aos modelos M1, M2, M3 e M4. O resultado do critério FPE e da validação cruzada (aplicação da equação 2.26) é mostrado no Quadro 6.2.

Quadro 6.2: Resultado das estimativas e validação dos modelos NARX

	Ordem $na, nb,$ nk	Modelo	FPE	Número de wavelets	Ajuste (%)
N1	2,1,1	$y1(k) = f(y1(k-1), y1(k-2), u(k-1))$	$1,08 \times 10^{-6}$	5	41,0
N2	2,2,1	$y1(k) = f(y1(k-1), y1(k-2), u(k-1), u(k-2))$	$0,964 \times 10^{-6}$	75	89,0
N3	3,2,1	$y1(k) = f(y1(k-1), y(k-2), y1(k-3), u(k-1), u(k-2))$	$1,02 \times 10^{-6}$	45	81,1
N4	2,3,1	$y1(k) = f(y1(k-1), y1(k-2), u(k-1), u(k-2), u(k-3))$	$1,03 \times 10^{-6}$	51	66,9

Como pode ser visto no Quadro 6.2, os resultados da validação cruzada apontaram o modelo N2 como o mais adequado para simular a saída do sistema.

A Figura 6.6 mostra uma janela de tempo da saída simulada, a qual foi obtida injetando a entrada presente no conjunto de dados de validação zvp , no modelo N2. Observa-se que o modelo N2 forneceu um ajuste satisfatório aos dados de validação, pois conseguiu capturar de modo aproximado o comportamento do sinal em frequência, e a maior parte do comportamento em amplitude.




Figura 6.6: Identificação da posição. Comparação entre saída medida (linha em preto) e saída simulada (linha em vermelho) para o modelo N2.

A Figura 6.7 mostra uma janela de tempo da saída simulada para o modelo N2, usando-se a como entrada a corrente de saída do motor presente no conjunto de dados de validação $Zvp2$ e comparando com a saída medida também presente em $Zvp2$.




Figura 6.7: Identificação da posição. Comparação entre saída medida (linha em preto) e saída simulada (linha em azul) para o modelo N2, usando-se o conjunto de dados de validação $Zvp2$. Uma janela de tempo de 85 segundos.

Com base na validação cruzada o modelo N2 foi escolhido para inferir a posição dinâmica da haste polida a partir da corrente de saída do inversor.

6.2 IDENTIFICAÇÃO PARA O SISTEMA: CORRENTE DE SAÍDA DO INVERSOR - CARGA NA HASTE POLIDA

Assim como para o problema de identificação realizado na seção anterior (seção 6.1), para a identificação do sistema em questão o modelo linear ARX foi primeiro identificado.

6.2.1 Análise Preliminar: Estimando o modelo linear ARX para carga

a) Determinação do Atraso

Como a posição e carga na haste polida estão diretamente relacionadas, não há necessidade em se estimar a resposta ao impulso, pois se o atraso entre a corrente de saída do inversor e a posição na haste polida é de 0,05 s (um período de amostragem, $nk = 1$), então do mesmo modo, tem-se que o atraso entre a corrente de saída do inversor e a carga suportada na haste polida também será de 0,05 s.

b) Determinação da Ordem do modelo

A determinação da ordem do modelo ARX do problema em questão foi feita partir do conjunto de dados de estimação Z_{ec} , aplicando-se o mesmo método visto na seção 6.1.1 para o problema de identificação que tem a corrente de saída do motor como entrada e a posição dinâmica da haste polida como saída. Primeiro, fixou-se $na = 1$ e variou-se nb de 1 até 10, observando-se a contribuição de nb para minimização do critério FPE, onde $nb = 2$ foi escolhido. Em seguida, fixou-se $nb = 2$ e variou-se na de 1 até 10, observando-se a contribuição de na para minimização de FPE. Os resultados são dados na Tabela 6.1.

Tabela 6.1: Resultado da estimação do modelo ARX para carga

na	nb	FPE
1	2	$1,94 \times 10^{-3}$
3	2	$1,45 \times 10^{-3}$
4	2	$1,45 \times 10^{-3}$
5	2	$1,43 \times 10^{-3}$
6	2	$1,42 \times 10^{-3}$
7	2	$1,42 \times 10^{-3}$
8	2	$1,40 \times 10^{-3}$
9	2	$1,40 \times 10^{-3}$
10	2	$1,40 \times 10^{-3}$

Observa-se na Tabela 6.1 que a partir de $na + nb = 5$, ou seja, $na = 3$, o critério FPE diminui de modo sucinto, se comparado com os decrementos do critério para $na + nb < 5$; isto sugere que o valor mais adequado para o autoregressor na do modelo linear ARX esteja entre $na + nb = 5$ e $na + nb = 8$.

c) Estimação dos Parâmetros e Validação

O Quadro 6.4 mostra o resultado da estimação do modelo ARX para as ordens anteriormente escolhidas, no caso, $nb = 2$ e $3 \leq na \leq 6$, onde $na \in \mathbb{N}$. Observa-se que o resultado da validação cruzada (*ajuste*), o qual foi obtido simulando cada um dos modelos estimados com o conjunto de dados de validação Z_{vc} , mostrou que os incrementos no valor de na para valores maiores do que 3 não causaram nenhuma melhoria relevante no ajuste do modelo.

Quadro 6.4: Resultado da estimação do modelo ARX para carga

	Ordem <i>na, nb, nk</i>	Modelo	FPE	Ajuste (%)
CL1	3,2,1	$y(k) = 1,316y_2(k-1) - 0,06351y_2(k-2) - 0,2966y_2(k-3) - 0,4459u(k-1) + 0,3953u(k-2)$	$1,05 \cdot 10^{-3}$	46,6
CL2	4,2,1	$y(k) = 1,289y_2(k-1) - 0,06928y_2(k-2) - 0,1769y_2(k-3) - 0,09101y_2(k-4) - 0,4107u(k-1) + 0,3555u(k-2)$	$1,04 \cdot 10^{-3}$	46,6
CL3	5,2,1	$y(k) = 1,301y_2(k-1) - 0,04629y_2(k-2) - 0,1679y_2(k-3) - 0,2585y_2(k-4) + 0,1299y_2(k-5) - 0,462u(k-1) + 0,4139u(k-2)$	$1,03 \cdot 10^{-3}$	46,7
CL4	6,2,1	$y(k) = 1,29y_2(k-1) - 0,02628y_2(k-2) - 0,1549y_2(k-3) - 0,2549y_2(k-4) + 0,02929y_2(k-5) + 0,07734y_2(k-6) - 0,4999u(k-1) + 0,4553u(k-2)$	$1,02 \cdot 10^{-3}$	46,6

A Figura 6.8 mostra uma janela de tempo do resultado da validação cruzada realizada para o modelo estimado CL1. Observa-se que o ajuste de 46,67% oferecido por este modelo é incapaz de reproduzir de modo aceitável o comportamento do sinal. Sendo assim, na próxima seção, o modelo de Hammerstein-Wiener será identificado.




Figura 6.8: Resultado da validação cruzada para o modelo CL1. Comparação entre saída medida (linha em preto) e saída simulada (linha em vermelho).

Ressalta-se, que em análises preliminares todos os modelos abordados no Quadro 2.1 foram testados; no entanto, referindo-se a identificação de sistemas dinâmicos lineares, como os resultados mais representativos foram obtidos por meio do modelo

ARX, para esta dissertação, referindo-se a identificação linear, apenas os resultados de tal modelo são mostrados.

6.2.2 Identificando o modelo de Hammerstein-Wiener

Como a identificação por meio da estrutura linear ARX não foi satisfatória, para a identificação de um modelo capaz de inferir a carga dinâmica suportada na haste polida a partir da corrente de saída do inversor, o modelo de Hammerstein-Wiener será usado.

a) Seleção da ordem e estimação dos parâmetros

Para a identificação usando o modelo de Hammerstein-Wiener, a função *wavelet network* foi escolhida como função estimadora de não-linearidade em ambas as funções de entrada (f_1) e saída (f_2). Em seguida, diversas ordens foram sugeridas para o modelo *OE* (*modelo do desvio na saída (como visto no Quadro 2.1, seção 2.1.4)*), e usando-se o conjunto de dados de estimação *Zec*, cada uma destas foram estimadas e avaliadas pela análise do critério FPE, como descritos no Quadro 6.5. Os resultados do cálculo do critério FPE sugerem que o modelo MHW6, com 1 função wavelet no bloco de entrada e 12 funções wavelets no bloco de saída, é o mais adequado dentre os modelos estimados para representar o sistema em questão. No entanto, como o modelo MHW5 apresenta praticamente o mesmo valor dado pelo critério FPE que o modelo MHW6 (apenas 1×10^{-4} a mais que o modelo MHW6), pode-se esperar que o resultado mais adequado a ser obtido durante a etapa de validação cruzada ocorra para o modelo que possui a menor ordem, como discutido na seção 2.1.6.

Quadro 6.5: Resultado da estimação do modelo ARX

	Ordem <i>nb, nf, nk</i>	Número de wavelets no bloco de entrada	Parte Linear (modelo do Desvio na Saída) $y_2(t) = [B(q)/F(q)]u(t)$	Número de wavelets no bloco de saída	FPE	Ajuste (/%)
MHW1	2,2,1	1	$B(q) = q^{-1} - 1,008q^{-2}F(q)$ $= 1 - 1,911q^{-1}$ $+ 0,9126q^{-2}$	9	$6,2 \cdot 10^{-3}$	76,8
MHW2	3,2,1	1	$B(q) = -0,5285q^{-1} +$ $q^{-2} - 0,4737q^{-3}F(q) = 1 -$ $1,985q^{-1} + 0,9872q^{-2}$	12	$11,4 \cdot 10^{-3}$	78,1
MHW3	2,3,1	1	$B(q) = q^{-1} - 1,001q^{-2}F(q) = 1 -$ $0,942q^{-1} - 0,9699q^{-2} + 0,9165q^{-3}$	9	$7,9 \cdot 10^{-3}$	75,9
MHW4	3,3,1	1	$B(q) = -0,5654q^{-1} + q^{-2} -$ $0,4368q^{-3}F(q) = 1 - 1,059q^{-1} -$ $0,8099q^{-2} + 0,8739q^{-3}$	11	$11,9 \cdot 10^{-3}$	75,2
MHW5	4,3,1	1	$B(q) = -0,3341q^{-1} + q^{-2} - 1,001q^{-3}$ $+ 0,3353q^{-4}$ $F(q) = 1 - 2,941q^{-1} + 2,893q^{-2} -$ $0,9514q^{-3}$	11	$5,7 \cdot 10^{-3}$	78,8
MHW6	4,4,1	1	$B(q) = -0,3342q^{-1} + q^{-2} - 1,001q^{-3}$ $+ 0,3351q^{-4}$ $F(q) = 1 - 2,159q^{-1} + 0,5934q^{-2} +$ $1,307q^{-3} - 0,7419q^{-4}$	12	$5,610^{-3}$	78,8
MHW7	5,5,1	1	$B(q) = 0,2987q^{-1} - 0,9265q^{-2} + q^{-3}$ $- 0,4117q^{-4}$ $+ 0,03948q^{-5}$ $F(q) = 1 - 0,9397q^{-1} - 0,5079q^{-2} +$ $0,1536q^{-3} + 0,2715q^{-4} + 0,02703q^{-5}$	9	$6,4 \cdot 10^{-3}$	76,4

b) Validação

Os resultados da validação cruzada, mostrados no Quadro 6.5, a qual é realizada simulando cada um dos modelos estimados com a corrente de saída do inversor presente no conjunto de dados de validação *Zvc*, confirma que o modelo MHW5, o qual possui 1 função wavelet no bloco de entrada 11 funções wavelets no bloco de saída, é o mais indicado, dentre os modelos estimados, para representar a dinâmica do sistema. O resultado da simulação e a comparação desta com o sinal de carga medido é dado Figura 6.9.




Figura 6.9: Resultado da validação cruzada para o modelo MHW5. Comparação entre saída medida (linha em preto) e saída simulada (linha em vermelho).

O resultado do cálculo do desvio de simulação (aplicação da equação 2.27) entre a saída real e a saída simulada dado na Figura 6.10 para o modelo MHW5, mostra a existência de um padrão periódico regular, além de diversos pulsos positivos e negativos. Tais períodos regulares e pulsos ocorrem devido ao comportamento cíclico da carga não explicado pelo modelo.

Na próxima subseção é descrito um procedimento a fim de melhorar o ajuste proporcionado pelo modelo MHW5.




Figura 6.10: Sinal de resíduos para o modelo MHW5.

6.2.3 Aumentando o ajuste dado pelo modelo MHW5: Conectando o modelo de HW ao modelo linear ARX

A fim de tornar a saída simulada do modelo MHW5, estimado na seção anterior, ainda mais próxima da saída desejada, propõe-se nesta seção o uso em série do modelo de Hammerstein-Wiener estimado e escolhido, o modelo MHW5, com o modelo ARX. O procedimento descrito na Figura 6.11 descreve a metodologia usada para o uso das estruturas em série.

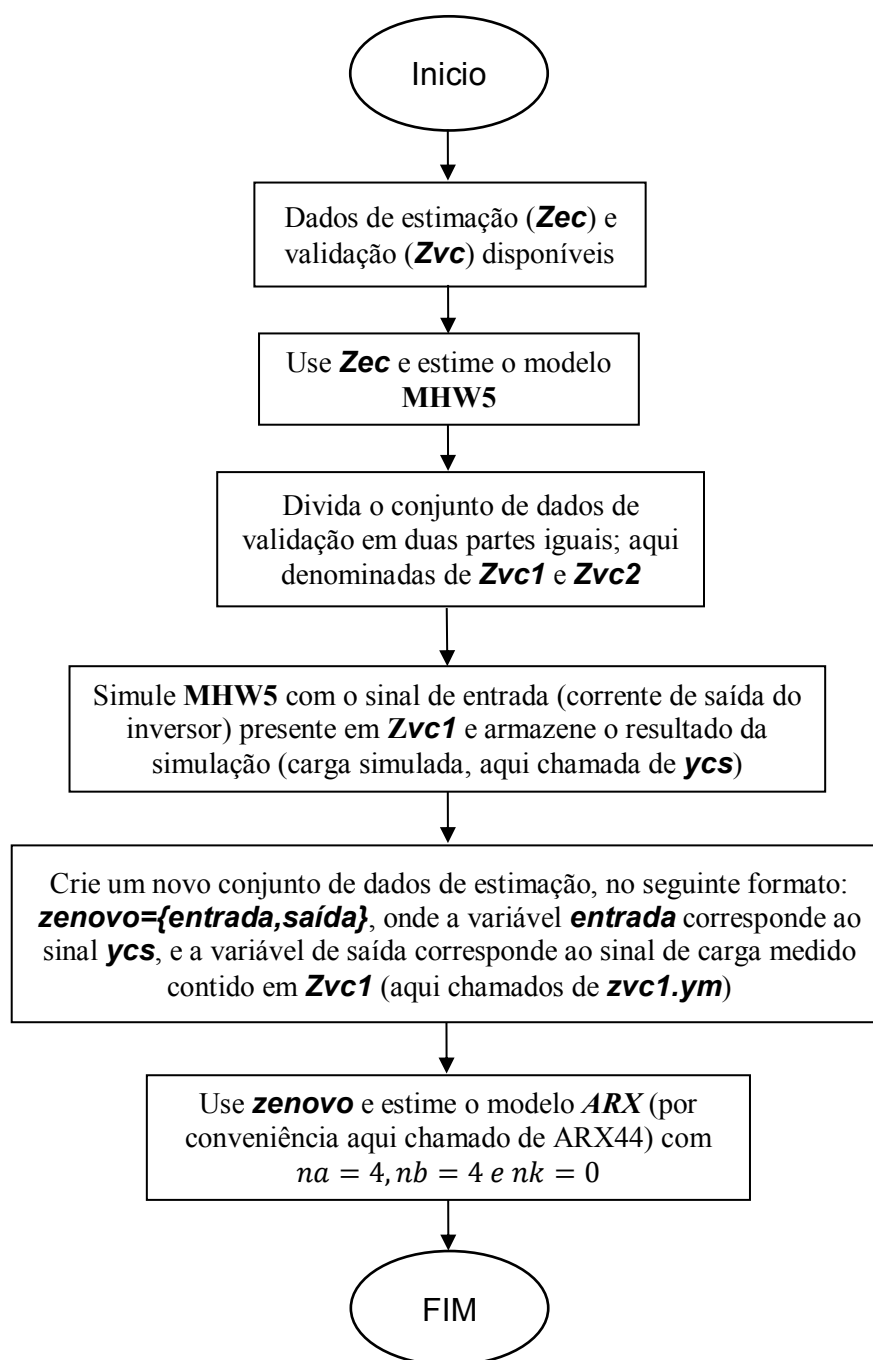


Figura 6.11: Procedimento para uso em cascata do modelo de HW (MHW5) com o modelo ARX (ARX44).

A escolha de $na = nb = 4$ para a identificação através do modelo ARX (modelagem esta que por conveniência será chamada de ARX44), foi feita baseada na mesma estratégia vista anteriormente nas demais identificações de posição e carga baseadas no modelo linear ARX. O resultado da estimação deste modelo é dado pela equação (6.1).

$$y(k) = 1,672y_2(k-1) - 0,7105y_2(k-2) - 0,03896y_2(k-3) + 0,01407y_2(k-4) + 0,9741u(k) - 1,526u(k-1) + 0,5671u(k-2) + 0,05806u(k-3) \quad (6.1)$$

Uma vez que o método dado pela Figura 6.11 tenha sido seguido para a estimação dos parâmetros do modelo HW-ARX (aqui chamado de HW-ARX-1), a simulação deste é feita de acordo com o diagrama de blocos apresentado na Figura 6.12.

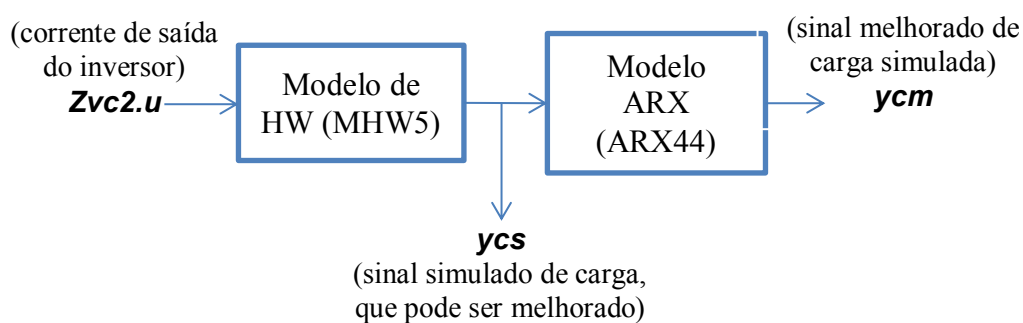


Figura 6.12: Estrutura HW-ARX-1 usada para obtenção da carga simulada a partir de corrente de saída do inversor.

A Figura 6.13 mostra uma janela de tempo com o sinal de carga medido, contido em $Zvc2$ (aqui chamado de $Zvc2.y$), além dos sinais y_{cs} e y_{cm} , obtidos após injetar a corrente de saída do inversor contida em $Zvc2$ (por conveniência chamada de $Zvc2.u$) na estrutura dada na Figura 6.12. Observa-se na Figura 6.13 que o modelo ARX44 aumentou a qualidade do ajuste dada pelo modelo MHW5. Em números, o modelo ARX44 proporcionou um acréscimo 7,87% no ajuste dado pelo modelo MHW5, o qual foi suficiente para aumentar a capacidade da estrutura para reproduzir a amplitude do sinal medido.




Figura 6.13: Comparação entre a saída medida (em preto), a saída simulada (ycs) dada pelo modelo MHW5 (em azul), e a saída simulada dada após a injeção do sinal ycs no modelo ARX (em vermelho).

Para a estrutura HW-ARX-1, o resultado do cálculo dos resíduos dado na Figura 6.14 mostra que o padrão periódico regular, o qual se refere à parte do sinal medido não explicada pelo modelo, possui uma amplitude menor do que o sinal de resíduos apresentado na Figura 6.10, devido ao melhor ajuste proporcionado por esta estrutura.




Figura 6.14: Resultado do cálculo dos resíduos.

A fim de avaliar a capacidade da estrutura do modelo HW-ARX-1 para simular a posição medida presente no conjunto de dados de extrapolação $Zvc2$, o qual contém um padrão de sinal da carga diferente das condições em que o mesmo foi treinado (região em que ocorre a condição de pancada de fluido), a corrente de saída do inversor presente em $Zvcp$ foi injetada na estrutura HW-ARX-1, e o sinal de carga simulado foi obtido, o qual é mostrado na Figura 6.15.




Figura 6.15: Comparação entre a saída medida (em preto) e a saída simulada (em vermelho) por meio do modelo HW-ARX-1.

Observa-se na Figura 6.15, que o modelo HW-ARX-1 não conseguiu reproduzir as características do sinal de carga medido presente em $Zvc2$. Como discutido no capítulo 2, tal resultado já era esperado, haja vista que uma estrutura caixa preta não é capaz de reproduzir comportamento para os quais não tenham sido previamente identificadas. Além do mais, análises preliminares mostraram que modelo HW-ARX-1 não é robusto o suficiente para reproduzir de modo satisfatório o comportamento dinâmico de carga contido nos dados de validação $Zvcp$ (região que envolve a condição de pancada de fluido), fazendo-se necessária o uso de outra estrutura.

A estrutura usada para simular o padrão de carga existente no conjunto de dados $Zvcp$, consiste de uma estrutura em partes similar ao HW-ARX-1; estimada e simulada do mesmo modo que descrito nas Figuras 6.11 e 6.12, respectivamente. A diferença da nova estrutura para o modelo HW-ARX-1 está na substituição do

modelo linear ARX, por um modelo de Hammerstein-Wiener, com $nb = 3, nf = 3$ e $nk = 1$; tais ordens e atrasos foram escolhidos de modo similar ao visto na seção 6.2.2-(a); o conjunto de dados $Zvcp$ foi dividido do seguinte modo:

$$Zvcpe = [u(30001), y_2(30001), \dots, u(32125), y_2(32125)],$$

$$Zvcpv1 = [u(32126), y_2(32126), \dots, u(33188), y_2(33188)] \quad \text{e}$$

$$Zvcpv2 = [u(33189), y_2(33189), \dots, u(34125), y_2(34125)]$$

onde $Zvcpe$, $Zvcpv1$ e $Zvcpv2$ foram usados para estimação e validação da nova estrutura (aqui chamada de MHW-MHW), e possuem função equivalente, respectivamente, aos conjuntos de dados Zec , $Zvc1$ e $Zvc2$, descritos na Figura 6.11. O resultado da validação cruzada, a qual foi obtida usando os dados de corrente presentes em $Zvcpv2$ no modelo MHW-MHW é mostrado na Figura 6.16.




Figura 6.16: Comparação entre a saída medida (em preto), a saída simulada (y_{cs}) dada pelo modelo MHW-MHW (em vermelho).

Observa-se na Figura 6.16 que o resultado da identificação foi satisfatório. Em números, o cálculo da equação do ajuste mostrou que tal estrutura conseguiu reproduzir 74% do comportamento do sistema.

6.3 GERAÇÃO DA CARTA DINAMOMÉTRICA COM OS MODELOS IDENTIFICADOS

Uma vez que os modelos tenham sido identificados a geração da carta dinamo-métrica, como vista na seção 4.3, é um traçado da posição (eixo das abscissas) *versus* a carga na haste polida (eixo das ordenadas). A Figura 6.17 resume o esquema usado para a simulação dos modelos identificados, a fim de se gerar a CDS.

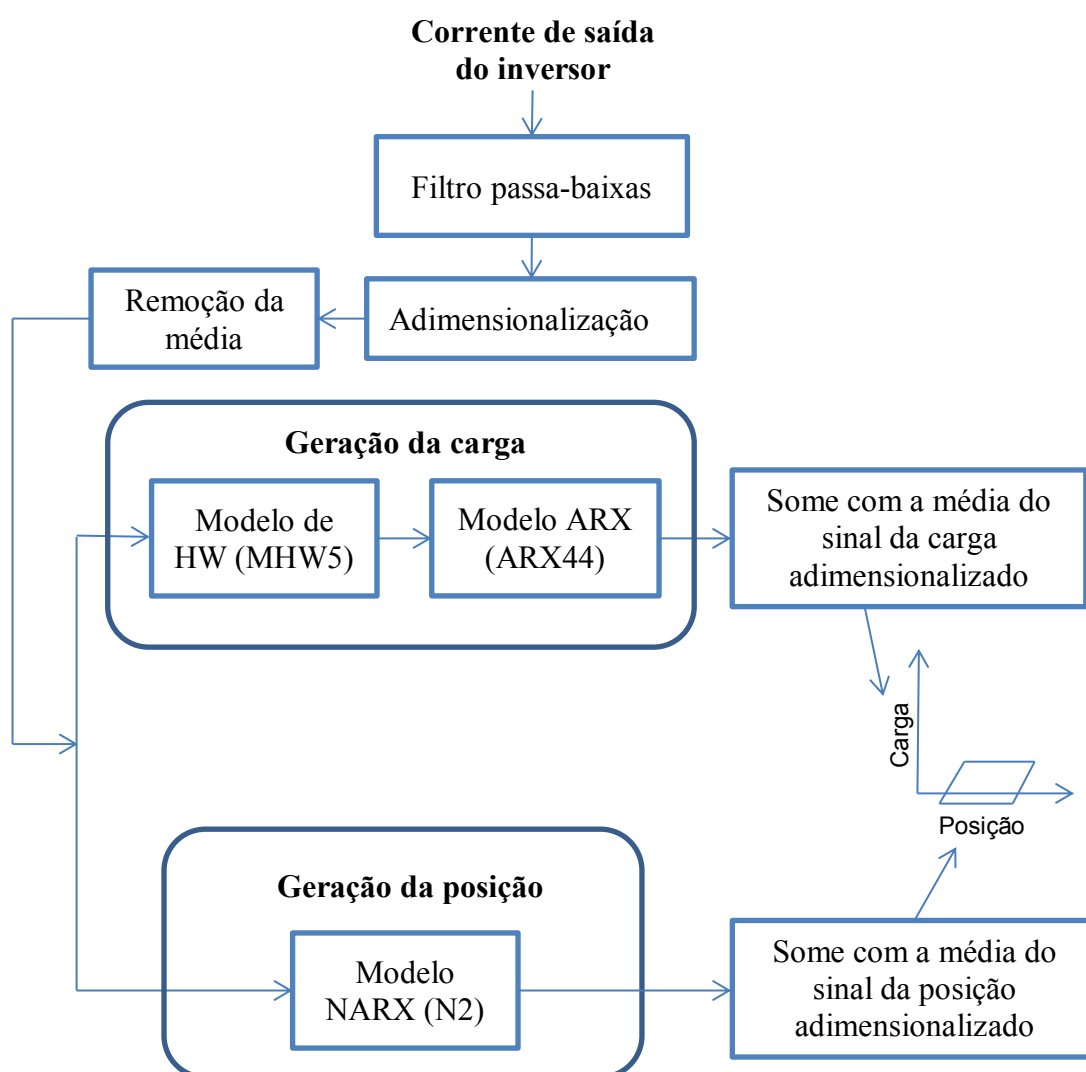


Figura 6.17: Estrutura geral usada na geração da carta dinamo-métrica a partir da corrente de saída do inversor.

A Figura 6.18 mostra uma janela de 172,55 segundos de cartas

dinamométricas de superfície obtidas a partir das variáveis medidas¹⁹ de posição e carga na haste polida, e a partir das simulações realizadas com base no esquema dado na Figura 6.17.




Figura 6.18: Carta dinamoétrica a partir da corrente de saída do inversor. A curva em preto refer-se a carta obtida por meio dos dados medidos; a curva em azul refer-se a carta obtida por meio da simulação.

Observa-se na Figura 6.18, que a carta dinamoétrica obtida por meio da simulação conseguiu acompanhar grande parte do padrão apresentado pela carta medida; sendo possível, a partir da carta simulada, obter muitas informações sobre o comportamento do sistema, como apresentado na seção 4.3.

A fim de gerar a CDS que mostra a condição de pancada de fluido, o modelo ARX44 mostrado na Figura 6.17 foi substituído pelo modelo de Hammerstein-Wiener MHW identificado na seção anterior (seção 6.2.3), cujas ordens são $nb = 3, nf = 3$ e $nk = 1$. O resultado da simulação é dado na Figura 6.19.

¹⁹ Os dados medidos de posição e carga na haste polida também foram adimensionalizados.




Figura 6.19: Carta dinamométrica a partir da corrente de saída do inversor. A curva em preto refer-se a carta obtida por meio dos dados medidos; a curva em azul refer-se a carta obtida por meio da simulação.

Observa-se na Figura 6.19, que é possível distinguir por meio da carta simulada a condição de pancada de fluido, no entanto, nota-se que existem regiões, (região que se inicia próximo ao início do curso descendente da haste de bombeio), que a estrutura MHW-MHW (a qual foi identificada na seção 6.2.3 para a condição de pancada de fluido) não foi capaz de reproduzir.

7 CONCLUSÕES, RECOMENDAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Este trabalho tratou da aplicação da identificação de sistemas dinâmicos a dois diferentes processos SISO, os quais envolvem o método de elevação artificial de petróleo por BM. O primeiro sistema SISO identificado possuía em sua entrada o sinal tratado da corrente de saída de inversor de frequência, e em sua saída o sinal tratado da posição dinâmica da haste polida da UB. O segundo sistema identificado também possuía o sinal tratado da corrente de saída do inversor de frequência em sua entrada, já a sua saída era o sinal de carga dinâmica suportada na haste polida.

Foi visto no capítulo 5, que os sinais candidatos à entrada na identificação de sistemas, a saber, tensão de saída do inversor, corrente de saída do inversor e corrente produtora de torque, possuíam, aproximadamente, a mesma correlação com os sinais de saída (posição e carga suportada na haste polida) e entre si. Por este motivo, apenas um dos sinais candidatos à entrada, a saber, a corrente de saída do inversor, foi escolhido para ser usado na identificação de sistemas, resultando em dois sistemas SISO. Após a identificação, a validade dos modelos obtidos foi dada pela comparação entre a saída simulada e a saída medida, usando-se um conjunto de dados diferentes do usado para a estimação dos parâmetros.

Para a identificação do sistema cuja variável de saída é a posição dinâmica da haste polida, e a variável de entrada a corrente de saída do inversor, o modelo NARX com $na = 2$, $nb = 2$, $nk = 1$ e com 75 funções de ativação wavelets, mostrou-se adequado para inferir, a partir da corrente de saída do inversor, a posição dinâmica da haste polida da BM, para o nível do anular variando da condição em que a CDS é considerada normal até a condição em que ocorre a pancada de fluido.

Para a identificação do sistema cuja variável de saída é a carga dinâmica suportada na haste polida e a variável de entrada a corrente de saída do inversor, não se conseguiu achar uma estrutura única de identificação que fosse capaz de representar toda a dinâmica do sistema, fazendo-se necessário a conexão de dois diferentes modelos.

A primeira estrutura, denominada neste trabalho de HWARX-1, a qual consiste da conexão em série do modelo de Hammerstein-Wiener com o modelo

ARX, foi capaz de inferir a carga dinâmica suportada na haste polida para a condição normal de CDS. Ressaltando-se que tal estrutura mostrou-se robusta para inferir a carga dinâmica mesmo com o nível do anular variando da condição de CDS normal até o momento que imediatamente antecede a condição de pancada de fluido. Já a segunda estrutura, neste trabalho chamada de MHW-MHW, a qual consiste do uso de dois modelos de Hammerstein-Wiener em série, foi capaz de inferir a partir da corrente de saída do inversor o comportamento da carga na região em que ocorre a condição de pancada de fluido.

Ainda com relação à identificação da carga suportada na haste polida, ressalta-se que ambas as estruturas obtidas, HW-ARX-1 e MHW-MHW, precisam ser melhoradas; especialmente a MHW-MHW, a qual é responsável na carta dinamométrica de condição pancada de fluido pela existência de uma região cujo modelo não consegue reproduzir, como detalhado na Figura 6.28. Contudo tal discrepância não interfere na classificação da CDS.

Ressalta-se que o comportamento não-estacionário apresentado no sinal de carga medida não representou um problema para a análise qualitativa da CDS.

Observou-se no capítulo 4 que para o método de elevação por BM podem ocorrer diferentes padrões de CDS, no entanto, este trabalho se concentrou em duas condições: normal e pancada de fluido; já que, de acordo com especialistas, estas são as condições que mais comumente ocorrem no método de elevação por BM.

A identificação não-linear mostrou-se promissora para o desenvolvimento de um instrumento virtual de elaboração de CDS a partir da medição de grandezas elétricas do sistema.

Sugestões para trabalhos futuros:

- testar as estruturas obtidas para a geração da CDS usando dados de corrente de saída do inversor coletados de diferentes poços equipados com o BM, a fim de saber se tais estruturas serão capazes de gerar a CDS;
- desenvolver modelos que sejam capazes de inferir a posição e carga dinâmica de haste polida de BM para as condições operacionais não

abordadas neste trabalho;

- este trabalho se concentrou no uso da *wavelet network* como função não-linear em f do modelo NARX e como função não-linear em f_1 e f_2 do modelo de Hammerstein-Wiener, sugere-se então que sejam testadas diferentes funções não-lineares em f , f_1 e f_2 e que os resultados sejam comparados com o presente trabalho;
- avaliar, no regime transitório, a incerteza dos dados experimentais, a matriz de variância dos parâmetros estimados e sua propagação para as grandezas de saída dos modelos identificados;
- desenvolver métodos de detecção de padrões de CDS a partir de variável(is) elétrica(s) fornecida(s) por inversor de frequência.

REFERÊNCIAS

AGUIRRE, L. A. **Introdução a Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**, Ed. UFMG, 2000.

AKAIKE, H. **Modern development of statistical methods**. Trends and Progress in System Identification. New York: Pergamon Press, pp. 169–184, 1981.

ALIPPI, C; PIURI V. **Experimental neural networks for prediction and identification**, *IEEE Transactions on Instrumentation and Measurement*, Vol. 45, No. 2, April, 1996.

BARNES, M. **Practical Variable Speed Drives and Power Electronics**, Elsevier. 1st edn, 2003.

BARRETO FILHO, M. A. **Geração de Carta Dinamométrica de Fundo para Diagnóstico do Bombeio Mecânico em Poços de Petróleo**. Dissertação de mestrado, UNICAMP, Campinas, 1993.

_____, **Curso de Formação de Operadores: Módulo Bombeio Mecânico**, Petrobras, 2002.

BENVENISTE, A; JUDITSKY A; B. DEYLON; ZHANG, Q; GLORENNEC, P. **Wavelets in Identification**. SYSID'94, 10th IFAC Symposium on System Identification, (Copenhagen), 1994.

BEZERRA, M. A. D. **Aplicação de redes neurais artificiais no reconhecimento de padrões de cartas dinamométricas de fundo em sistemas de bombeio mecânico de petróleo**. 2010. Dissertação de mestrado - UFBA.

BOSE, B. K. **Modern Power Electronics and AC Drive**. Prentice Hall, 2002.

BOX, G. E. P; HUNTER, J. S; HUNTER, W. G. . **Statistics for experimenters - Design, Innovation, and Discovery**. 2nd ed., John Willey & Sons, 2005.

BRADLEY, H. B., **Petroleum Engineering Handbook**, Third printing, Society of Petroleum Engineers, USA, 1992.

BRETSCHER, O. **Linear Algebra With Applications**. 3rd ed. Upper Saddle River

NJ: Prentice Hall, 1995.

BÜHLER, W. K. **Gauss: A Biographical Study**. Berlin: Springer-Verlag, 1981.

CAJUEIRO, E.; KALID, R.; SCHNITMAN, L. **Using NARX model with wavelet network to inferring the polished rod position**. International journal of Mathematics and Computers in simulation, vol. 6, no. 1, p. 66-73, 2012.

_____. **Inferring Polished Rod Position from Torque Current of the Motor**. In the book "Recent Advances of Applied & Biomedical Informatics and Computational Engineering in Systems Applications", Included in ISI/SCI Web of Science and Web of Knowledge, Florence, Italy, pp. 283-288, 2011 (a).

_____. **Inferindo Posição de Haste de Bombeio Mecânico a Partir de Corrente de Motor**. Anais do X Congresso Brasileiro de Inteligência Computacional (CBIC'11), Fortaleza - CE, Nov. 2011 (b).

_____. **Identificação de Sistemas Dinâmicos Utilizando Modelos ARX e Não-Linear ARX**. Anais do VII Seminário Nacional de Controle e Automação Industrial, Elétrica e de Telecomunicações (VII SNCA), Salvador - BA, Nov. 2011 (c).

CHEN, S.; BILLINGS, S; LUO, W. **Ortogonal least squares methods and their application to nonlinear system identification**. Int. J. Control, vol. 50, no. 5, p. 1873-1896, 1989.

COLEMAN, D. E; MONTEGOMERY, D. C. **A systematic approach to planning for a designed industrial experiment**. Technometrics, v.35, n.1, 1993.

COOK, M; GRAHAM, M. **Hydrocarbon exploration and production**, Developments in Petroleum Science, No. 46, Elsevier, 2003.

CUTLER, R; MANSURE, A. J. **Fluid Dynamics in Sucker Rod Pumps**. U.S. Department of Energy's (DOE), Technical report, Available in <<http://www.osti.gov/bridge/purl.cover.jsp?purl=/3261-6aA2W9/webviewable/>>, acessado em: 03 de abril de 2010.

DAUBECHIES, I. **Orthonormal Bases of Compactly Supported Wavelets**, Comm. Pure Appl. Math., vol. 41, p. 909-996, 1988.

_____. **Ten Lectures on Wavelets**. Society for Industrial & Applied Mathematics, Philadelphia, 1992.

DE NICOLAO, G.; TRECATE, G. F. **Consistent identification of NARX models via regularization networks**, IEEE Trans. on Automatic Control, - Special issue on Neural Networks in control, identification and decision making, Vol. 44, No. 11, 2045-2049, 1999.

DELYON, B; JUDITSKY, A; BENVENISTE, A. **Accuracy analysis for wavelet approximations**, IEEE Transactions on Neural Networks, Vol. 6, No. 2, march, 1995.

DONG, B. JI, H. JIA, L. SHEN, Z. E YUHONG, X, **Wavelet frame based blind image in painting**, Applied and Computational Harmonic Analysis, Volume 32, Issue 2, March 2012, p. 268-279.

DOTY, D.R; SCHMIDT, Z. **An improved model for sucker-rod pumping**. Soc. Pet. Eng., 1983, p. 34-41.

DOYLE, F.J., PEARSON, R.K; OGUNNAIKE, B. A. **Identification and Control Using Volterra Models**. New York, Springer-Verlag, 2001.

DUFFIN, R.J; SHAEFFER, A.C. **A class of nonharmonic Fourier Series**. Trans. Amer. Math. Soc. 72, 147-158, 1952.

EL-ASHI, Y.; DHAOUADI, R.; LANDOLSI, T. **MODELING AND ANALYSIS OF A WAVELET NETWORK-BASED OPTICAL SENSOR FOR VIBRATION MONITORING**, Sensors Journal, IEEE , vol.11, no.8, pp.1657-1668, Aug. 2011

FEDERBUSH, P. **Quantum field theory in ninety minutes**. Bull. Amer. Math. Soc. 17, 93-103, 1987.

FONTES, C. H. O.; EMBIRUÇU, M. **Multivariable Correlation Analysis and its Application to an Industrial Polymerization Reactor**. Computers and Chemical Engineering, v. 25, p. 191-201, 2001.

FOURIER, J. B. JOSEPH. **Théorie Analytique de la Chaleur**, Paris, 1822.

GABOR, D. **Theory of Communication**. J. Inst. Elec. Eng. (London), Vol. 93, p. 429-457, 1946.

GARCIA, C. **Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos**, 2ª Ed., Ed. Edusp, 2005.

GIBBS, S. G. **Prediction of the behavior of a sucker-rod pumping system**. J Pet, Eng. p.769-778, 1963.

GIBBS, S. G.; MILLER, D. L. **Inferring power consumption and electrical performance from motor speed in oil-well pumping units**. IEEE Transactions on Industry Applications, Vol. 33, No. 1, January/February, 1997.

GIBBS, S. G; NEELY, A. B. **Computer Diagnosis of Down-Hole Conditions in Sucker Rod Pumping Wells**. Journal of Petroleum Technology, p.91-97, 1966.

GREBLICKI, W; Pawlak, M. **Nonparametric System Identification**. Cambridge University Press, 2008.

GRIVA, I; NASH, S. G; SOFER, A. **Linear and Nonlinear Optimization**, 2nd ed. Philadelphia: SIAM, 2009.

GROSSMAN, A; MORLET, J. **Decomposition of Hardy functions into square integrable wavelets of constant shape**. SIAM J. Math. Anal., Vol. 15, No. 4, p. 723-736, 1984.

HAAR, A. **Zur Theorie der Orthogonalen Funktionen-Systeme**. Math. Ann. 69, p. 331-371, 1910.

HAN, L; NEUMANN, M. **Inner Product Spaces, Orthogonal Projection, Least Squares, and Singular Value Decomposition**. Discrete Mathematics and Its Applications - Handbook of Linear Algebra, Chapman & Hall/CRC, 2007.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Pearson Education, 2nd Edition, 1998.

HAYKIN, S; VEEN, B. V. **Sinais e Sistemas**. 2ª ed. Porto Alegre: Bookman, 2001.

HOJJATI, M.H; LUKASIEWICZ, S.A. **Modelling of sucker rod strings**. Journal of

Canadian Petroleum Technology 44 (12), 2005, p. 55–58.

IFEACHOR, E. C; JERVIS, B. W. **Digital Signal Processing - A Practical Approach**, 2nd edn, Pearson Education, 2002.

ISERMANN, R, M; MÜNCHHOF, M. **Identification of Dynamic Systems - An Introduction with Applications**. Springer, 2010.

JENSEN, A; COUR-HARBO, A. **Ripples in mathematics - The discrete wavelet transform**. Springer Verlag. 2001.

JUDITSKY, A. A.; HJALMARSSON, H. B.; BENVENISTE, A. A.; DELYON, B. A.; LJUNG, L. B; SJOBERG, J. B; ZHANG, Q. **Nonlinear black-box models in system identification: Mathematical foundations**. Automatica, 31, p. 1725-1750, 1995.

KARNY, M. AND PAVELKOVA, L. **Projection-based Bayesian recursive estimation of ARX model with uniform innovations**. Systems & Control Letters, 56, 646-655, 2007.

KRONLAND-MARTINET R; MORLET, J; GROSSMANN, A. **Analysis of sound patterns through wavelet transform**. Internat. J. Pattern Recognition and Artificial Intelligence, 1988.

KUGARAJAH, T; ZHANG, Q. **Multidimensional wavelet frames**. IEEE Transactions on Neural Networks, vol. 6-6, pp. 1552-1556, 1995.

LEKIA, S. D. L; EVANS, R. D. **Coupled Rod and Fluid Dynamic Model for Predicting the Behavior of Sucker - Rod Pumping System**. Society of Petroleum Engineers – 21664, p. 297-312, 1991.

LEONTARITIS, I. J; BILLINGS, S. A. **Experimental design and identifiability for nonlinear systems**. Int. J. Control, 45(1): 1987, p. 311-341.

LIN, C-M, HSU, C-F, CHUNG, C-M, **Adaptive control for mimo uncertain nonlinear systems using recurrent wavelet neural network**, International Journal of Neural Systems (IJNS), Vol. 22, pp. 37-50, 2012.

LIU, Z.; WANG, X.; QIAN, Q. **A review of wavelet networks and their applications**, Automation of Electric Power System, 27(6), 73–9, 2003.

LIUS G.P; BILLINGS, V. Kadiramanathan, **Nonlinear system identification using wavelets networks**, Internat. Conference on control '98, 1-4 September, 1998.

LJUNG, L. **Black-box Models from Input-output Measurements**. IEEE Instrumentation and Measurement Technology Conference, Hungary, 2001.

_____. **Nonlinear Black-Box Modeling in System Identification**. Internal report, Dept. of. Electrical Engineering, Linköping University, 1997.

_____. **System Identification - Theory for the User**. 2nd ed., Prentice-Hall, Englewood Cliffs, N.J, 1999.

LJUNG, L; GLAD, T. **Modeling of Dynamic Systems**. Prentice-Hall, 1994.

LJUNG, L; HJALMARSSO, H. **System Identification Through The Eyes Of Model Validation**. In Proc. Third European Control Conference, volume 3, Rome, Italy, pp 949-954, September, 1995.

MALLAT, S. G. **A theory for multiresolution signal decomposition: the wavelet representation**. vol. 11, p. 674-693, July, 1989.

MASOUM, M.A.S.; JAMALI, S.; GHAFARZADEH, N.; **Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks**, Science, Measurement & Technology, IET , vol.4, no.4, pp.193-205, July 2010

MEYER, Y. **Ondelettes, fonctions splines et analyses graduées**, Lecture notes, Univ. of Torino, Italy, 1986.

_____. **Principe d'incertitude, bases hilbertiennes et algèbres d'opérateurs**. Séminaire Bourbaki, 662, 1985.

MAHFOUF, M.; KANDIAH, S.; LINKENS, D. A. **Fuzzy model-based predictive control using an ARX structure with feedforward**. Fuzzy Sets and Systems, 125, 39-59, 2002.

MISKA, S; SHARAKI, A; RAJTAR, J.M. **A simple model for computer-aided optimization and design of sucker-rod pumping systems**. Journal of Petroleum Science and Engineering, 17, p. 303-312, 1997.

MONTEGOMERY, D. C. **Design and analysis of experiments**. New York: Wiley, 1976.

MOORE, E. H. **On the reciprocal of the general algebraic matrix**. Bulletin of the American Mathematical Society 26 (9), p. 394–395, 1920.

MORLET, J. **Sampling theory and wave propagation**. NATO ASI Series, Vol. 1, Issues in Acoustic signal/Image processing and recognition, C. H. Chen, Berlin: ed. Springer-Verlag, p. 233-261, 1983.

NARENDRA, K.; PARTHASARATHY, K. **Identification and Control of Dynamical Systems Using Neural Networks**. IEEE Trans. Neural Networks, 1:4-27, 1990.

NARENDRA, K.; GALLMAN, P. G. **An iterative method for identification of nonlinear system using a Hammerstein model**. IEEE Transactions on Automatic Control, vol. AC-11, N° 3, pp. 546-550, 1966.

NASCIMENTO, J. M. A. **Simulador Computacional para Poços de Petróleo com Método de Elevação Artificial por Bombeio Mecânico**. Dissertação de mestrado, UFRN, 2005.

NELLES, O. **Nonlinear System Identification: From Classical Approaches to Neural Network and Fuzzy Models**, Springer, 2001.

ORDOÑEZ, B. **Proposta de Controle de Operação de Poços com Bombeio Mecânico Através da Pressão de Fundo**. Dissertação de mestrado, UFSC, 2008.

RAJAMANI, P.; DEY, D.; CHAKRAVORTI, S. **Cross-correlation aided wavelet network for classification of dynamic insulation failures in transformer winding during impulse test**, Dielectrics and Electrical Insulation, IEEE Transactions on , vol.18, no.2, pp.521-532, April 2011

ROSS, T. J. **Fuzzy logic with engineering applications**, 2010.

SAFAVI A, A; ROMAGNOLI, J.A. **Application of Wavelet-based Neural Networks to the Modelling and Optimisation of an Experimental Distillation**. Engng Applic. Artif. Intell, Vol. 10, No. 3, p. 301-313, 1997.

_____. **Application of Wave-nets to Modelling and Optimisation of a Multidimensional Chemical Process**. Australia: IEEE Xplore Digital Library, 2006.

SJÖBERG, J; ZHANG, Q; LJUNG, L; BENVENISTE, A; DEYLON, B. **Nonlinear Black-Box Modeling in System Identification: A Unified Overview**. Automatica 31, 12, 1995.

SMITH, J. G., S. KAMAT, K.P. MADHAVAN, **Modeling of pH process using wavenet based Hammerstein model**. Journal of Process Control 17, 551–561, 2007.

SÖDERSTRÖM, T. STOICA, P. **System Identification**, Prentice-Hall Int., London, 1989.

SONTAG, E. D. **Feedforward Nets for Interpolation and Classification**. J. Comp. Syst. Sc., 1991.

TAKACS, G. **Sucker-rod Pumping Manual**, PennWell Books, 2002.

_____. **Ways to Decrease Production Costs for Sucker-rod Pumping**, Internal report, Petroleum Engineering Department, University of Miskolc, Hungary, 2000.

TADAYONI, A., XIE, W-F, GORDON, B. W. **Adaptive control of harmonic drive with parameter varying friction using structurally dynamic wavelet network**, international journal of control, automation and systems, Volume 9, Number 1, pp.50-59, (2011).

VERHAEGEN M; VERDULT, V. **Filtering and System Identification - A Least Square Approach**, Cambridge University Press, 2007.

SHI, Y.; YANG, X. **The Lifting Factorization and Construction of Wavelet Bi-Frames With Arbitrary Generators and Scaling**, Image Processing, IEEE Transactions on , vol.20, no.9, pp. 2439-2449, Sept. 2011

ZADEH, L. A. **Fuzzy Sets**. Information and Control, vol. 8, p. 338-353, 1965.

ZHANG, Q. **Wavelet Network: The Radial Structure and an Efficient Initialization Procedure**. Sweden, 1993 (a). Linköping University. Publicação Interna. Disponível em <ftp://ftp.irisa.fr/local/wavenet/rep-linkoping.ps.gz>. Acesso em 08 de março de 2010.

_____. **Regressor Selection and Wavelet Network Construction**. Institut National de Recherche en Informatique, Rapport de recherche, April, 1993 (b), ISSN 0249-6399.

_____. **Using wavelet network in nonparametric estimation**. IEEE Transactions on Neural Network, Vol. 8, No. 2, March, 1997.

ZHANG, J.; GAO, X.P.; LI, Y.Q. **Efficient wavelet networks for function learning based on adaptive wavelet neuron selection**, *Signal Processing*, IET, vol.6, no.2, pp.79-90, April 2012

ZHANG, Q; BENVENISTE, A. **Wavelet networks**, IEEE Trans. Neural Networks, NN-3(6), 889-898, 1992.

ZHANG, Z.; LIU, G. & LIU, F. **Construction of a new adaptive wavelet network and its learning algorithm**. Science China Press, co-published with Springer, 2001, 44, 93-103.

ZHU, Y. **Estimation of an N-L-N Hammerstein-Wiener model**. 15th Triennial World Congress, Barcelona, Spain, 2002.

Créditos de Figura: Silva, W. M, Santos, J. C., Nascimento, R. J, Reis, P. R. C. Apresentação Interativa "Elevação Artificial em poços de Petróleo," Lagarto/SE, agosto, 2002.

LISTA DE PULBLICAÇÕES

Artigos em revista:

1. CAJUEIRO, E.; KALID, R.; SCHNITMAN, L. **Using NARX model with wavelet network to inferring the polished rod position**. International Journal of Mathematics and Computers in Simulation, vol. 6, no. 1, pp. 66-73, 2012.

Artigos em eventos:

2. CAJUEIRO, E.; KALID, R.; SCHNITMAN, L. **Inferring Polished Rod Position from Torque Current of the Motor**. In the book “Recent Advances of Applied & Biomedical Informatics and Computational Engineering in Systems Applications”, Included in ISI/SCI Web of Science and Web of Knowledge, Florence, Italy, pp. 283-288, 2011 (a);
3. CAJUEIRO, E.; KALID, R.; SCHNITMAN, L. **Inferindo Posição de Haste de Bombeio Mecânico a Partir de Corrente de Motor**. Anais do X Congresso Brasileiro de Inteligência Computacional (CBIC'11), Fortaleza - CE, Nov. 2011 (b);
4. CAJUEIRO, E.; KALID, R.; SCHNITMAN, L. **Identificação de Sistemas Dinâmicos Utilizando Modelos ARX e Não-Linear ARX**. Anais do VII Seminário Nacional de Controle e Automação Industrial, Elétrica e de Telecomunicações (VII SNCA), Salvador - BA, Nov. 2011 (c).

UFBA
UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA

PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA INDUSTRIAL - PEI

Rua Aristides Novis, 02, 6º andar, Federação, Salvador BA
CEP: 40.210-630
Telefone: (71) 3283-9800
E-mail: pei@ufba.br
Home page: <http://www.pei.ufba.br>

