

# INFERINDO POSIÇÃO DE HASTE DE BOMBEIO MECÂNICO A PARTIR DE CORRENTE DE MOTOR

Emanuel Benício de Almeida Cajueiro\*, Ricardo de Araújo Kalid\*, Leizer Schnitman\*.

\* Programa de Pós-graduação em Engenharia Industrial, Universidade Federal da Bahia, Rua Aristides Novis, nº 02, Escola Politécnica, 2º andar, 40.210-630, Salvador, Bahia, Brasil.  
emanuelbenicio@hotmail.com, kalid@ufba.br, leizer@ufba.br

**Resumo** – Este trabalho apresenta resultados experimentais que mostram que a posição dinâmica de haste de bombeio mecânica pode ser inferida a partir da corrente de motor de indução trifásico, utilizando modelos de identificação de sistemas não-lineares. Uma atenção particular é dada ao ciclo de identificação, a fim de se utilizar uma metodologia adequada para obtenção dos modelos. Os experimentos foram realizados em um laboratório desenvolvido para testes. Um conjunto de dados de entrada e saída foram coletados sob condições controladas, os quais foram divididos em dados de estimação e validação. Modelos NARX baseados em wavelet network, foram usados para realizar a identificação do sistema. As performances desses modelos estimados foram avaliadas por meio do erro médio quadrático (MSE). Os resultados obtidos na etapa de validação mostram que, para o conjunto experimental utilizado neste trabalho, o melhor modelo estimado pode ser usado no lugar dos transdutores físicos de posição.

**Palavras-chave** – unidade de bombeio mecânico, ciclo de identificação, posição dinâmica, NARX, wavelet network.

## 1 Introdução

A unidade de bombeio mecânico (UBM) é o método de elevação artificial mais utilizado para poços de petróleo terrestres [1]. Devido razões estratégicas e econômicas, para a indústria do petróleo, torna-se essencial conhecer as condições do poço e controlar a sua produção. A UBM age de maneira a transformar o movimento de rotação de um motor, em um movimento alternativo vertical, de modo a fornecer energia para a elevação do fluido [2]. Este movimento alternado (posição dinâmica) da haste polida da UBM auxilia no diagnóstico das condições do poço podendo ser usado em seu controle [2]. Embora muitos artigos tenham sido publicados dando ênfase à modelagem fenomenológica da relação unidade de bombeio mecânico e poço de petróleo [3]-[7], ainda nos dias de hoje, a aquisição em campo da posição da haste da UBM é feita utilizando transdutores físicos de posição (em geral encoder). Recentemente, foi mostrado em [8] que a posição dinâmica da haste polida da UBM pode ser inferida a partir da corrente de torque de motor de indução trifásico, fornecida por inversor de frequência vetorial. Contudo este trabalho mostra que a posição dinâmica da haste de bombeio mecânico pode ser inferida diretamente da corrente de saída de inversor de frequência (que é a corrente de entrada do motor), dispensando assim o uso da corrente de torque. Assim como em [8], neste artigo são usados modelos de identificação de sistemas não-lineares [8]. Uma das principais vantagens desse tipo de abordagem, é que não se faz necessário o uso de nenhum outro equipamento adicional para ser instalado em campo, uma vez que a estrutura de identificação pode ser implementada diretamente no inversor de frequência.

A obtenção de modelos matemáticos capazes de representar as características estáticas e dinâmicas de um sistema real, baseados nos dados experimentais, constitui o princípio básico da identificação de sistemas. Embora em alguns casos as aproximações lineares [9], [10] sejam suficientes para representar aplicações práticas, os sistemas dinâmicos encontrados no mundo real são, em última análise, não-lineares [11]. Para sistemas que operam em larga faixa de operação ou sistemas altamente não-lineares, modelos lineares não são suficientes [12]. Modelos não-lineares como redes neurais artificiais (RNAs) [13], modelos não-lineares autoregressivos com entradas exógenas (NARX) [12] e de Hammerstein-Wiener [13], baseados em RNAs e em wavelet networks (wavenet) [14], têm recebido muita atenção nas três últimas décadas [13]-[21], devido à aprendizagem de mapeamentos complexos a partir de um conjunto de dados reais. 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 foram treinados [12].

Trabalhos importantes no estudo das decomposições wavelets, como em [21] e [22], possibilitaram a [14] o desenvolvimento da *wavenet*. A *wavenet* foi proposta a princípio como alternativa à rede neural *feedforward* [13]. De acordo com [17], 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 *wavenet* é uma decomposição *wavelet* [21] implementada em uma rede neural de uma camada escondida, onde as *wavelets* são funções de ativação dos neurônios escondidos [23]. A decomposição *wavelet* é uma ferramenta poderosa para identificação de sistemas devido à capacidade de aproximar funções em diferentes escalas [21]. De acordo com [23], 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 bases da decomposição *wavelet* não são rígidas, uma vez que se adaptam aos dados observados [17]. O resultado da combinação da decomposição *wavelet* e das redes neurais se resume em uma ferramenta com métodos construtivos eficientes [14], [15], [17], [22]-[25], para a escolha da estrutura e determinação dos parâmetros da rede, e capaz de resolver problemas de larga dimensão [17].

Apesar das técnicas de identificação de sistemas lineares e não-lineares (como as citadas anteriormente) serem ferramentas robustas para a modelagem de sistemas dinâmicos, é importante ressaltar que a identificação caixa preta não é uma tarefa trivial [13], e que o seu sucesso nem sempre ocorre de acordo à aplicação de uma lógica síncrona. A identificação de sistemas é um processo que em geral envolve muitas etapas, todavia, muitas vezes quando são representadas e/ou descritas na literatura (como em [9] e [10]), encontram-se condensadas em poucos blocos ou simplesmente não são consideradas. Abordagens simplificadas são interessantes do ponto de vista teórico, pois em geral são suficientes para identificação de sistemas virtuais (descritos por equações matemáticas e simulados em software). No entanto, a aplicação prática desses diagramas para a identificação de sistemas reais pode exigir mais esforço do que o representado, uma vez que algumas etapas importantes (como a perturbação da planta e o tratamento do sinal amostrado) são situações que devem ser tratadas com a especificidade de cada caso. Baseado nas metodologias utilizadas em [9], [10], [11] e [13], neste artigo são abordados (de maneira sucinta) todos os pontos da metodologia da identificação aqui desenvolvida.

Este trabalho é organizado da seguinte forma: na seção 2, o diagrama de blocos é desenvolvido para identificação do sistema da unidade de bombeio mecânico (UBM); na seção 3, realiza-se uma breve revisão teórica a respeito do modelo NARX e da wavenet; na seção 4, descreve-se o sistema utilizado para coleta dos dados e logo em seguida, inicia-se a identificação do sistema; na seção 5, a identificação é concluída e os resultados são apresentados. Por fim, a conclusão é feita na seção 6.

## 2 Metodologia para Identificação de Sistemas

Nesta seção é descrito de maneira sucinta os principais blocos representados na Figura 1. O leitor deve se reportar a [9]-[19], [26], [27] para uma abordagem detalhada sobre os aspectos teóricos que envolvem cada um destes blocos.

- Bloco “*Escolha o Sinal de Entrada*”: De acordo com [9], “o sinal de entrada precisa ter alguma relação com o sinal de saída fim de a modelagem fazer sentido”. Funções de correlação cruzada entre os sinais pretendentes à entrada e entre os sinais de entrada e saída ajudam fortemente na escolha das variáveis amostradas serem usadas na identificação [10], [13]. Técnicas mais elaboradas como PCA (do inglês: análise dos componentes principais) também podem ser usadas [13];
- Bloco “*O sistema permite manipular o sinal de entrada?*”: Em alguns sistemas é possível manipular diretamente o sinal de entrada, seja aplicando degraus, gerando sinais aleatórios, pseudo-aleatórios, etc [12]. Em outros tipos de sistemas o usuário apenas consegue observar o sinal de entrada, sendo impossível a sua manipulação por via direta;
- Bloco “*Escolha uma variável capaz de excitar o sistema, de modo a excitar os sinais que serão coletados*”: Para o caso em que não se pode manipular diretamente o sinal de entrada, faz-se necessário escolher, sempre que possível, uma variável manipulável do sistema a fim de causar as excitações desejáveis a serem capturadas pelo “sinal observável”, citado no parágrafo acima;
- Bloco “*Escolha o tempo de amostragem*”: sinais subamostrados tornam o modelo identificado incapaz de reproduzir as características do sistema a ser identificado, por outro lado, sinais superamostrados possuem redundância de informação no sistema identificado pela adição de parâmetros linearmente dependentes [10]. Para o caso de sinais superamostrados, a técnica da análise da autocovariância linear e não-linear [10] pode ser usada para se determinar uma taxa de reamostragem [28], a partir dos dados previamente amostrados;
- Bloco “*Os dados precisam ser tratados?*”: O usuário deve verificar se há a necessidade de filtrar os dados coletados, remover seu nível DC, reamostrá-lo, etc [10]. A análise em frequência dos sinais amostrados é de grande valor para as tomadas de decisão [9]. É importante ressaltar que na maioria dos casos, o mesmo processo de tratamento deve ser aplicado a ambos os sinais de entrada-saída coletados, a fim de manter as possíveis relações lineares.
- Bloco “*Pré-processe os dados*”: Consiste em aplicar técnicas de processamento digital de sinais [28], a fim de adequar os dados coletados, para a etapa de estimação dos parâmetros;
- Bloco “*O sistema é linear?*”: Caso essa informação seja desconhecida e seja possível perturbar o sistema em questão, recomenda-se [10], [12] testes básicos como observar a dimensão do ganho obtido em malha aberta em resposta a um pequeno degrau. Se a não-linearidade estática é forte, então o ganho estático irá mudar significadamente, para diferentes pontos de operação dentro da faixa operacional [13]. Caso os dados já tenham sido coletados e esta informação ainda não tenha sido obtida, recomenda-se, em [9] e [13], a estimação não-paramétrica da resposta ao impulso para obter algum conhecimento sobre o sistema;
- Bloco “*Determine/escolha a estrutura linear*”: Refere-se à seleção do modelo linear (no caso ARX [9], ARMAX [10], *Box-Jenkins* [10], erro na saída [13], etc), da ordem (pólos e zeros), número de atrasos e tempo morto do modelo [27]. Critérios como MSE (do inglês, *mean square error* – erro médio quadrático), AIC (do inglês, *Akaike information critério* – critério de informação de Akaike), função custo, FPE (do inglês *final prediction error* – erro de predição final), etc, são normalmente usados [9]. A função custo é definida por  $V_n(\theta|Z^N) =$

$\det(V_a)$ , onde:  $V_a = 1/N \sum_{k=1}^N \varepsilon(t, \theta_n) (\varepsilon(t, \theta_n))^T$ ,  $Z^N = [y(1), u(1), y(2), u(2), \dots, y(N), u(N)]$  é o conjunto de dados amostrados, e  $\varepsilon(k, \theta_n) = y(k) - \hat{y}(k|\theta_n)$  é o erro de predição parametrizado por  $\theta$ . Já para o FPE, tem-se:  $FPE = \left[ \frac{n+n\theta}{n-n\theta} \right] V_n(\theta|Z^N)$ , onde  $n_\theta$  é o número de parâmetros estimados e os demais termos foram definidos anteriormente. Para o MSE, tem-se  $MSE = 1/N \sum_{k=1}^N (y(k) - \hat{y}(k))^2$  [9]. Este tópico é discutido detalhadamente em [9];

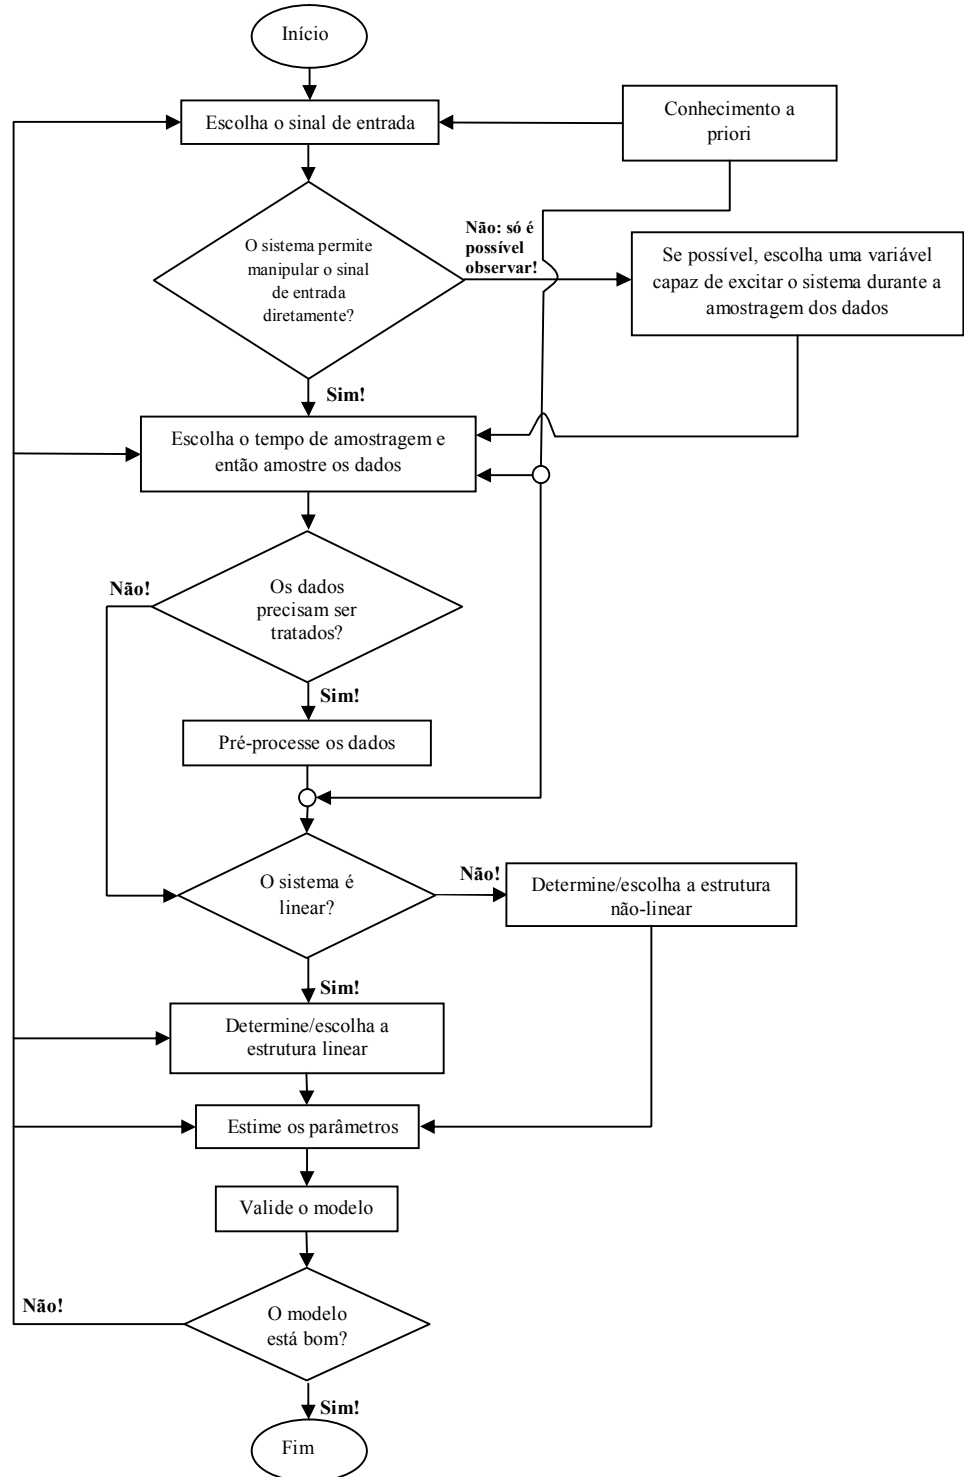


Figura 1– Ciclo de identificação de sistemas.


- Bloco “*Determine/escolha a estrutura não-linear*”: Refere-se à seleção do modelo não-linear, dos regressores (entradas e saídas deslocadas no tempo) padrão ou de regressores não-lineares, geralmente para os modelos NARX e NOE (do inglês: *nonlinear output error*) [15]. Para os modelos de Hammerstein-Wiener refere-se à seleção da ordem do bloco linear [13]. Com relação aos estimadores de não-linearidade, refere-se à quantidade de neurônios e camadas, funções de ativação, algoritmo de treinamento, etc [8];
- Bloco “*Ajuste o modelo aos dados*”: Observando os dados que são apresentados a estrutura escolhida, o computador estima/seleciona os parâmetros do modelo utilizando algoritmos de treinamento. Detalhes sobre os algoritmos de treinamento para sistemas lineares podem ser vistos em [10]. Para sistemas não-lineares em [26] são detalhados os algoritmos de aprendizagem das diversas estruturas de RNAs e em [17] e [14] são descritos os principais algoritmos de aprendizagem das wavenets;
- Bloco “*Valide o modelo*”: Durante a validação, deve-se utilizar um conjunto de dados independente dos dados de estimação para que o que os resultados obtidos não sejam tendenciosos [15]. Em seguida, utiliza-se uma equação capaz de mostrar o ajuste do modelo obtido aos dados experimentais de validação. A chamada “equação do ajuste” (do inglês, *fit*) pode ser utilizada, esta equação lembra a função do coeficiente de determinação  $R^2$  (que também é normalmente utilizada para este fim) e representa o percentual da variação de saída que é explicada pelo modelo pode ser usada. No caso,  $fit = \left(1 - \frac{\sum_{k=1}^N \|y_k - y_{sk}\|}{\sum_{k=1}^N \|y_k - \bar{y}\|}\right) \times 100$ , onde  $y_k(y, \dots, y_N)$  é a saída medida,  $y_{sk}(y_s, \dots, y_N)$  é a saída simulada do modelo,  $\bar{y}$  é a média do vetor  $y_k$ , e  $\|\cdot\|$  representa a norma euclidiana [10].

### 3 NARX e Wavelet Networks

Nesta seção são revisados os modelos que serão aplicados no estudo de caso.

#### A. Modelo NARX

O modelo NARX é baseado no modelo linear ARX e corresponde a um subsistema do modelo NARMAX, por conter apenas a sua parte determinística [13]. A estrutura NARX utilizada neste trabalho é uma combinação série-paralela, como mostra a Figura 2 (a). Onde, os valores medidos de entrada atuais e passados de  $u$ , e os valores medidos passados de  $y$  são arranjados no primeiro bloco (bloco de construção dos regressores). Em seguida, entram em ambos os blocos pertencentes ao estimador de não-linearidade  $f$ .



**Figura 2** - Estruturas NARX com configuração série-paralela para identificação de sistemas (a) e simulação (b).

Baseado na Figura 2(a) pode-se escrever a equação do modelo NARX

$$\hat{y}(k) = f(x) = F(x(k)) + x(k)\theta^T + l \quad (1)$$

Em que  $F(\cdot)$  representa a saída do bloco de função não-linear,  $x(k) = [y(k-1), \dots, y(k-na), u(k-nk), \dots, u(k-nk-nb+1)]$  é vetor de regressores de entrada da rede, onde  $na$  representa o número de auto-regressores,  $nb$  representa o número de regressores exógenos,  $nk$  é o número de amostras de entrada que ocorre antes da entrada afetar a saída.  $x(k)\theta^T + l$  é a saída da função linear,  $\theta$  representa os coeficientes lineares, e  $l$  é o offset de saída [17], [29]. O bloco linear é inserido na estrutura estimadora de não-linearidade, a fim de melhor condicionar o sinal de saída. A capacidade de aproximação da função linear é discutida detalhadamente em [29].

Uma vez que o modelo tenha sido identificado de acordo com a configuração da Figura 2 (a), a configuração da Figura 2 (b) será considerada para a simulação. Na Figura 2(b) nota-se que os dados preditos na saída do sistema são realimentados na rede (de acordo com a escolha dos regressores) a fim de se obter a saída esperada. Vale lembrar que no processo de simulação serão considerados dados diferentes dos usados na estimação, a fim de se validar o modelo.

#### B. Wavelet Networks

A wavelet network utilizada neste trabalho é formada por wavelets radiais que constituem um *frame*<sup>1</sup>(quadro) em  $L^2(\mathbb{R}^n)$ , e foram propostas em [14] devido a similaridade entre a transformada wavelet inversa discretizada (ver [21] para mais detalhes)

<sup>1</sup> Wavelets radiais que satisfazem a condição de frame fornece um método conveniente para a construção de wavelets multidimensional [11]. O leitor pode se referir a [15] para uma discussão detalhada sobre wavelet frames.

e a rede neural de uma camada escondida [26]. A idéia básica é que um sinal  $f(x) \in L^2(\mathbb{R}^n)$  pode ser representado como uma soma ponderada de funções wavelets radiais

$$f(x) = \sum_{k=1}^{ns} a_{sk} \varphi(D_{sk}(x - r)Q - t_{sk}) + \sum_{k=1}^{nw} \omega_{wk} \psi(D_{wk}(x - r)Q - t_{wk}) + x(k)P\theta^T + l \quad (2)$$

Em que, a função gaussiana  $\varphi(x) = e^{-\frac{\|x\|^2}{2}}$  e a segunda derivada da função Gaussiana (o chamado "chapéu mexicano")  $\psi(x) = (\dim(x) - \|x\|^2)e^{-\frac{\|x\|^2}{2}}$  correspondem, respectivamente, a função de escala (também chamada de wavelet pai) e a função wavelet (conhecida como wavelet mãe). As quais foram escolhidas para compor a função expansão (2), devido à boa localização tempo-frequência [21]. Onde  $x$  corresponde ao vetor de regressores dilatado, transladado e bem condicionado (aplicando técnicas de análise dos componentes principais (PCA)) [13]. Onde,  $r$  é a média do vetor de regressores (1 x m),  $P$  é uma matriz de subespaço linear (m x p),  $Q$  é uma matriz do subespaço não-linear (m x q) obtida através da aplicação da análise dos componentes principais aos regressores em  $x$ ,  $\theta^T$  é o vetor de coeficientes lineares estimados da função afim (p x 1);  $a_{sk}$  é o vetor de coeficientes associado com os scalons (ns x 1),  $\omega_{wk}$  é o vetor de coeficientes associado com os wavelons (nw x 1),  $D_{sn}$  é a matriz de dilatação associada com os scalons (ns x 1),  $D_{wn}$  é a matriz de dilatação associada com os wavelons (nw x 1);  $t_{sn}$  é a matriz de translação associada com os scalons (ns x q),  $t_{wn}$  é a matriz de translação associada com os wavelons (nw x q),  $l$  é offset de saída (escalar), ns é o número de scalons e nw o número de wavelons. A arquitetura da wavelet network usada neste trabalho é mostrada na Figura 3.




Figura 3 – Estrutura típica da wavelet network.

Lembrando que a wavenet utilizada neste trabalho representa o bloco estimador não-linear da estrutura NARX. Então, para a parte não-linear e para a parte linear da estrutura NARX e da wavenet, respectivamente, pode-se verificar que:  $F(\cdot)$  (do modelo NARX) =  $\sum_{k=1}^{ns} a_{sk} \varphi(\cdot) + \sum_{k=1}^{nw} \omega_{wk} \psi(\cdot)$  (da wavenet); e  $x(k)\theta^T + l$  (do modelo NARX) =  $x(k)P\theta^T + l$  (da wavenet). A inicialização dos parâmetros da rede advém das informações fornecidas pela decomposição wavelet [17]. Os algoritmos de treinamento da estrutura e seleção de funções bases utilizados neste artigo, são detalhados em [17].

A escolha do número de funções bases utilizadas na estrutura wavenet deste artigo foi feita através do algoritmo de validação cruzada generalizada (do inglês *generalized cross-validation (GCV)*) [17]. Este algoritmo escolhe as funções que melhor contribuem para minimização do erro de estimação

$$GCV(S) = \frac{1}{N} \sum_{k=1}^n (\hat{f}(u_k) - y_k)^2 + 2S \frac{1}{N} \sigma_e^2 \quad (3)$$

onde, GCV é minimizado com respeito a  $S$ .  $\hat{f}_s$  é a aproximação dada pela wavenet ao sinal de entrada  $u_k$ ,  $S$  é o número de funções de base da rede,  $N$  é o comprimento dos dados amostrado,  $y_k$  é a saída e  $\sigma_e^2$  é a variância do ruído. Os algoritmos de estimação dos parâmetros da rede são detalhados em [14], [19].

## 4 Estudo de Caso

O experimento relatado nesta seção foi realizado no laboratório de elevação artificial (LEA), localizado na Escola Politécnica da Universidade Federal da Bahia. Foi identificada a relação posição de haste de bombeio mecânico e corrente de saída do inversor.

O leitor interessado pode-se reportar a [2] para uma abordagem detalhada sobre o funcionamento da unidade de bombeio.

### A. O poço de petróleo e unidade de bombeio mecânico

Para realização do experimento foi utilizado um poço desenvolvido para testes. No caso, um poço vertical com 32 metros de profundidade, com fundo visível e acessível, uma unidade de bombeio mecânico (UBM) e um sistema SCADA (do inglês *Supervisory Control and Data Acquisition* – sistema de supervisão, controle e aquisição de dados). A unidade de bombeio é

equipada com um motor assíncrono de indução trifásico com 5 HP, 6 pólos e velocidade nominal de 1160 RPM controlada por inversor de frequência<sup>2</sup> (do inglês *AC-drive*) [30]. A Figura 4 (a) ilustra de maneira simplificada o poço de petróleo e a UBM utilizados no experimento. O sistema de aquisição da posição, controle do motor e aquisição da corrente é detalhado na Figura 4 (b).

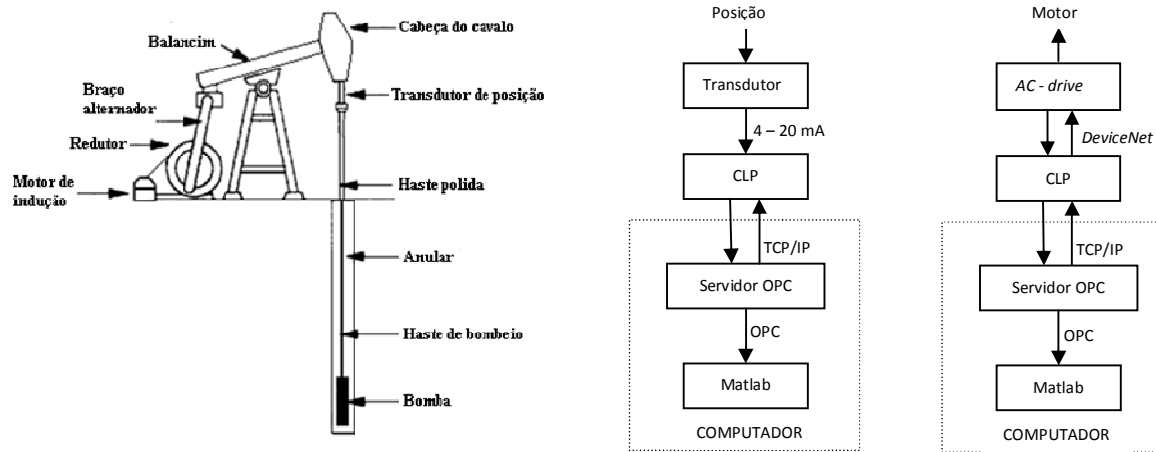


Figura 4– Conjunto de experimentos. Poço de petróleo e unidade de bombeio (a), e sistema de aquisição de posição, e corrente (b).

### B. Ciclo de Identificação

Baseado em conhecimento a priori, o período de amostragem de 0,05 segundos foi escolhido e os sinais de entrada  $u(k)$  (corrente de entrada de motor de indução trifásico) e saída  $y(k)$  (posição de haste de bombeio mecânica) foram amostrados. Um total de 26000 amostras ( $Z^N = \{u(1), y(1), \dots, u(26000), y(26000)\}$ ) de dados foram adquiridas (ver Figura 5 (a)), e os dados foram então divididos em dados de estimação ( $ze = \{u(1), y(1), \dots, u(16000), y(16000)\}$ ) e dados de validação  $zv = \{u(16001), y(16001), \dots, u(26000), y(26000)\}$ . A fim de excitar a dinâmica do sistema e simular condições reais de operação, a frequência da unidade de bombeio foi variada de maneira aleatória e o nível do poço foi variado da condição de operação normal, até a condição de pancada de fluido<sup>3</sup>. A análise da correlação cruzada [10] mostrou que os sinais são fortemente correlacionados, portanto faz sentido obter um modelo que relacione essas variáveis. Aplicando a transformada rápida de Fourier (FFT) [28] ao sinal de saída ( $y(k)$ ) observou-se que a máxima frequência que este sinal pode alcançar é de 0,15 Hz, e que ele não está corrompido com ruído de potência espectral relevante, como mostra Figura 5 (b). Aplicando a transformada rápida de Fourier (FFT) ao sinal de entrada ( $u(k)$ ) observou-se que este sinal possui um espectro rico em harmônicos, bem como ruído branco de baixa potência adicionado (ver Figura 5 (c)). Portanto, a fim de adequar este sinal para a identificação de sistemas, uma vez que estes harmônicos e ruídos são desinteressantes para esta aplicação, um filtro elíptico digital passa baixa de primeira ordem [28], no caso  $H(z) = (0.084817z + 0.084817)/(z - 0.83037)$  foi projetado. Este mesmo filtro também foi aplicado ao sinal de saída  $y(k)$ , a fim de manter as possíveis relações lineares. Desta forma, foram obtidos dados filtrados de estimação (chamados de  $zef$ ) e validação (chamados de  $zvf$ ).

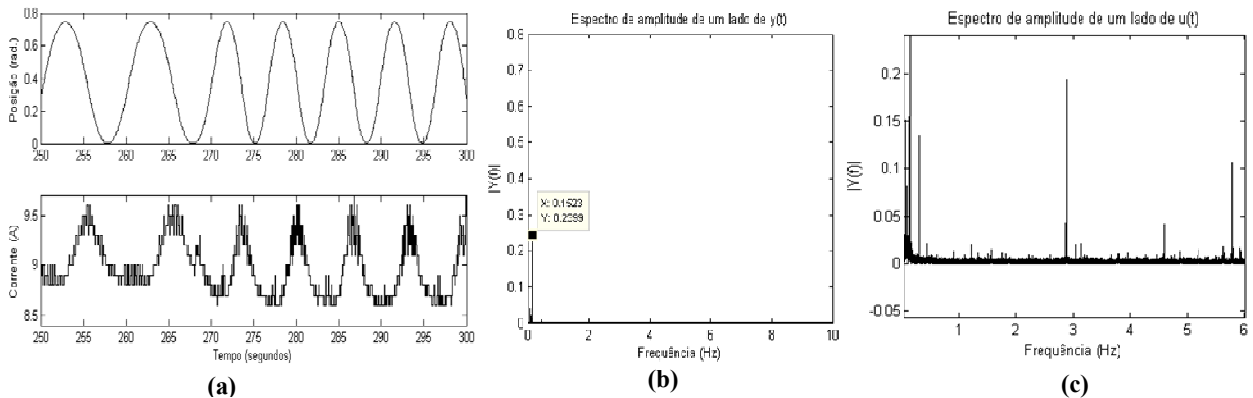


Figura 5 – (a) Uma janela de tempo de 150 segundos do conjunto de dados de posição (saída ( $y$ )) e corrente (entrada ( $u$ )). Espectro de amplitude de lado único do sinal de saída (b), e entrada (c).


<sup>2</sup> No caso, inversor com controle vetorial de fluxo sem sensor (*sensorless*). O leitor pode referir-se a [24] para uma abordagem detalhada sobre este equipamento.

<sup>3</sup> A pancada de fluido ocorre quando o nível no anular é insuficiente para o enchimento completo da câmara de pistão (ver [2] para mais detalhes).

## 5 Resultados

Como era conhecido priori que o sistema em questão é fortemente não-linear, o modelo NARX baseado em wavelet networks foi escolhido para identificação do sistema. Três diferentes ordens de termos regressores foram sugeridas para e. Em seguida, estes modelos foram estimados, usando o conjunto de dados de estimação  $zef$ , e avaliados pela análise erro médio quadrático (MSE). Como mostra a Tabela I, o resultado dado pelo MSE sugere que modelo NARX-2, construído com 17 scalons (funções  $\varphi$ ) e 58 wavelons (funções  $\psi$ ) (selecionados pelo critério da validação cruzada generalizada (GCV) dado em (3)) irá superar todos os demais modelos estimados na etapa de validação. Após simular a saída ( $\hat{y}(k)$ ) de NARX-1, NARX-2 e NARX-3, injetando a sequência de entrada  $u(k)$  presente no conjunto de dados de validação  $zvf$ , e comparando com a saída filtrada também presente em  $zvf$ , constatou-se pela observação da equação do ajuste, que o modelo NARX-1 não possuía termos regressores suficientes para representar adequadamente a dinâmica do sistema. Também se observou que o modelo NARX-3 sofreu aumento da variância do erro de estimação, devido à grande quantidade de regressores utilizados. No entanto, o resultado obtido para o modelo NARX-2,  $\hat{y}(k) = \hat{f}(\hat{y}(k-1), \hat{y}(k-2), u(k-1), u(k-2))$ , superou todos os demais modelos estimados, com um ajuste de 91,35% (ver Figura 6 (a)).

Para efeito de comparação, o mesmo sistema também foi identificado com o modelo linear ARX, dado pela seguinte forma:  $y(k) + a_1y(k-1) + \dots + a_nay(k-na) = b_1u(k-nk) + \dots + b_nbu(k-nk-nb+1) + e(k)$ . Onde os parâmetros foram estimados minimizando a função custo [10]. Este modelo corresponde ao caso particular do modelo não-linear ARX, quando  $f$  é uma função linear. O resultado da simulação, para o modelo estimado com  $na = 2$ ,  $nb = 2$  e  $nk = 1$  (mesma ordem escolhida para estimação de NARX-2) são mostrados na Figura 6 (b).



**Figura 6** – Comparação entre dados medidos (linha contínua) e dados simulados (linha tracejada) para o modelo, NARX-2 (a), e o modelo linear ARX (b). Uma janela de tempo de 50 segundos.

**Tabela 1** – Resultado para a estimação dos parâmetros e ajuste.

Modelo	Regressores	Nº de Wavelets	MSE	Ajuste (%)
NARX-1	$x(k) = [y(k-1), u(k-1), u(k-2)]$	114	$47,29 \cdot 10^{-02}$	-2,32
NARX-2	$x(k) = [y(k-1), y(k-2), u(k-1), u(k-2)]$	75	$0,41 \cdot 10^{-02}$	91,35
NARX-3	$x(k) = [y(k-1), y(k-2), y(k-3), u(k-1), u(k-2)]$	54	$1,30 \cdot 10^{-02}$	81,15

## 6 Conclusão

Baseado no ciclo de identificação desenvolvido, este trabalho apresentou uma estimativa de um sistema da unidade de bombeio mecânico. A validade do modelo foi obtida pela comparação entre a saída simulada e a saída medida. Os resultados obtidos mostraram que o modelo NARX baseado em wavelet networks construído com 75 wavelets, superou os demais modelos estimados, mostrando-se suficiente para inferir a posição dinâmica da haste de bombeio mecânico, a partir da corrente de entrada de motor de indução trifásico, que é dada por inversor de frequência vetorial. Isto mostra que é possível vislumbrar a substituição do sensor de posição utilizado na unidade de bombeio mecânico, por um modelo caixa-preta não-linear, o qual pode ser incorporado em um sistema de microprocessado.

## 7 Referências

- [1] M. Cook and M. Graham, Hydrocarbon exploration and production, **Developments in Petroleum Science**, No. 46, Elsevier, (2003).
- [2] H.B. Bradley, Petroleum Engineering Handbook, **Third Printing Society of Petroleum Engineers**, U.S.A., (1992).
- [3] S. G. Gibbs and D. L. Miller, 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).
- [4] S.G. Gibbs, Prediction of the behavior of a sucker-rod pumping system, **J. Pet. Eng.** (1963),769-778.
- [5] D.R. Doty and Z Schmidt, An improved model for sucker-rod pumping, **Soc. Pet. Eng.**, pp 34-41, (1983).
- [6] S. Miska, A. Sharaki, and J.M. Rajtar, A simple model for computer-aided optimization and design of sucker-rod pumping systems, **Journal of Petroleum Science and Engineering**, 17 (1997), 303-312,
- [7] M.H. Hojjati, S.A. Lukasiewicz, Modelling of sucker rod strings, **Journal of Canadian Petroleum Technology** 44 (12) (2005), 55–58.
- [8] E. B. A. Cajueiro, R. A. Kalid, and L. Schnitman, Inferring Polished Rod Position from Torque Current of the Motor, Proceedings of the **IAASAT International Conference on Environment, Economics, Energy, Devices, Systems, Communications, Computers, Pure and Applied Mathematics**, Florence, Italy, August 23-25, (2011) (to be published).
- [9] T. Söderström and P. Stoica, System Identification, **Prentice-Hall Int.**, London, (1989).
- [10] L. Ljung, System Identification - Theory for the User, 2nd edn., **Prentice-Hall**, Englewood Cliffs, N.J., (1998).
- [11] L. A. Aguirre, Introdução a Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais, **Ed. UFMG**, (2000).
- [12] L. Ljung, Black-box models from input-output measurement, **IEEE Instrumentation and Measurement, Technology Conference**, Budapest, Hungary, May 21-23, (2001).
- [13] O. Nelles, Nonlinear System Identification: From Classical Approaches to Neural Network and Fuzzy Models, **Springer**, (2001).
- [14] Q. Zhang, and A. Benveniste, Wavelet networks, **IEEE Trans. Neural Networks**, NN-3(6), 889-898, (1992).
- [15] J. Sjöberg et al., Nonlinear black-box modeling in system identification: a unified overview, **Automatica**, Vol. 31, No. 12, (1995), 1691-1724.
- [16] C. Alippi and V. Piuri, Experimental neural networks for prediction and identification, **IEEE Transactions on Instrumentation and Measurement**, Vol. 45, No. 2, April, (1996).
- [17] Q. Zhang, Using wavelet network in nonparametric estimation, **IEEE Transactions on Neural Network**, Vol. 8, No. 2, March (1997).
- [18] G.P. Liu, S. A. Billings, and V. Kadirkamanathan, Nonlinear system identification using wavelets networks, **Internat. Conference on control '98**, 1-4 September, (1998).
- [19] I.J. Leontaritis, S.A. Billings, Input-output parametric models for nonlinear systems. Part I: deterministic nonlinear systems, **Internat. J. Control**, 41 (2), (1985), 303-328.
- [20] M.C.S. Coelho, L.A. Aguirre, e M.V. Corrêa, Metodologia para representação de modelos NARX polinomiais na forma de Hammerstein e Wiener, **Tendências em Matemática Aplicada e Computacional**, 3, No. 1, (2002) , 71-80.
- [21] I. Daubechies, Ten Lecture on Wavelets, **Society for Industrial and Applied Mathematics**, Pennsylvania, (1992).
- [22] S. G. MALLAT, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation, **IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE**. VOL. II, NO. 7. July (1989).
- [23] B. Delyon, A. Juditsky, and A. Benveniste, Accuracy Analysis for Wavelet Approximations, **IEEE TRANSACTIONS ON NEURAL NETWORKS**, VOL. 6, NO. 2, MARCH (1995).
- [24] S. A. Billings and S. Y. Fakhouri, Identification of a class of nonlinear systems, **IEE/IEEE Colloq. Identification Nonlinear Systems; IEE Digest 78/31**, London, May, (1978).
- [25] A.A. Safavi, J.A. Romagnoli, Application of Wave-nets to Modelling and Optimisation of a Multidimensional Chemical Process, **IEEE Xplore Digital Library**, Australia, (2006).
- [26] S. Haykin, Neural Networks: A Comprehensive Foundation, **Pearson Education**, 2nd Edition, (1998).
- [27] A. Juditsky, H. Hjalmarsson, A. Benveniste, B. Delyon, L. Ljung, J. Sjöberg, and Q. Zhang., Nonlinear black-box modelling in system identification: mathematical foundation, **Automatica**,31, (1995).
- [28] E. C. Ifeachor, B. W. Jervis, Digital Signal Processing - A Pratical Approach, 2nd edn, **Pearson Education**, (2002).
- [29] E. D. Sontag, Feedforward Nets for Interpolation and Classification, **J.Comp.Syst.Sc**, (1991).
- [30] M. Barnes, Practical Variable Speed Drives and Power Electronics, **Elsevier**, 1st edn, (2003).