



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

IDENTIFICAÇÃO DE MODELOS BASEADOS EM REDES NEURAIAS ARTIFICIAIS PARA SIMULAÇÃO TRIDIMENSIONAL DE UM SISTEMA VIBRO-ACÚSTICO DINÂMICO

Magalhães, Robson da Silva, RobsonM@cimatec.fieb.org.br¹

Fontes, Cristiano H. O, cfontes@ufba.br²

Almeida, Luiz A. L, lalberto@ufba.br²

Embirucu, Marcelo, embirucu@ufba.br²

¹SENAI - CIMATEC,

²UFBA - Universidade Federal da Bahia.

***Resumo:** Este trabalho propõe uma estrutura de modelo baseada em uma Artificial Neural Networks (ANN) para a modelagem dinâmica da transmissão acústica entre uma fonte primária enclausurada em uma sala e um receptor posicionado em um ponto qualquer no interior dessa sala. Esse modelo está baseado em redes neurais treinadas por um algoritmo BackPropagation (BP) e deve descrever o comportamento do processo investigado, ou seja, deve se constituir em um modelo para a simulação tridimensional de emissões acústicas originadas da vibração de uma máquina. Na identificação da dinâmica do sistema, é usada uma estrutura de modelo MISO (Multi-Input Single-Output). Os resultados mostram que o modelo obtido é consistente e descreve adequadamente as principais dinâmicas do fenômeno estudado, evidenciando que a abordagem MISO, usando-se uma ANN, é adequada à simulação do processo investigado e que a estrutura proposta para o modelo dinâmico é promissora, considerando-se a sua futura aplicação em sistemas para Active Noise Control (ANC).*

***Palavras-chave:** Redes Neurais; Identificação Não Linear; Modelos Dinâmicos; Sistemas de Parâmetros Distribuídos; Sistemas Vibro-Acústicos*

1. INTRODUÇÃO

Considerando os requisitos de desempenho exigidos em muitas das atuais aplicações que utilizam modelos matemáticos, o comportamento da maioria dos fenômenos físicos pode ser representado por sistemas lineares. Os procedimentos de identificação paramétrica para sistemas lineares são bem consolidados e apresentam inúmeros resultados teóricos e práticos [1, 2]. Alguns sistemas deixam de ter o seu comportamento bem descrito por modelos lineares se suas fronteiras ou as faixas de valores em que são excitados são estendidas. Nestes casos, necessita-se de um modelo não linear, e a identificação de sistemas não lineares usando redes neurais vem despertando interesse e tem sido aplicada com sucesso já há algum tempo [3, 4, 5].

As técnicas de modelagem que utilizam Artificial Neural Networks (ANNs) têm sido fortemente pesquisadas e aplicadas em problemas de controle e identificação a cerca de vinte anos. Especificamente em sistemas vibro-acústicos, as ANNs têm sido utilizadas em reconhecimento de voz [6], na avaliação da qualidade sonora em espaços urbanos [7], na identificação de formas geométricas através da identificação das frequências naturais em uma resposta acústica [8] e no diagnóstico de falhas [9]. Suas grandes vantagens são trabalhar como uma “caixa-preta” e também terem a habilidade de aproximar complexos mapeamentos não lineares, adequando-se às não linearidades existentes em exemplos de comportamentos (já conhecidos) de um sistema. Este mapeamento não linear, realizado pelas ANNs, é baseado em medidas de entrada e de saída do processo a ser modelado. Devido a estas características, atualmente as ANNs têm sido bastante exploradas também na identificação de sistemas dinâmicos não lineares [10], modelando esta relação não linear entrada/saída do processo identificado, com as variáveis variando ao longo do tempo. Nestes casos, a representação da dinâmica pode ser caracterizada através da alimentação do conjunto de sinais e (entrada e saída do processo) atrasados no tempo na entrada da ANN, para contemplar o tempo morto, a memória da entrada e o feedback associados à fenomenologia do sistema, acarretando em uma representação entrada/saída segundo uma arquitetura recorrente [11, 12].

Alguns trabalhos com ANN também têm sido desenvolvidos para aplicações em controle ativo de ruído (Active Noise Control, ANC). Bambang [13] desenvolveu uma aplicação em ANC utilizando redes neurais recorrentes. Neste trabalho o autor apresenta um algoritmo de aprendizado para redes neurais recorrentes com base no filtro de Kalman. A

estrutura global para ANC proposta foi construída utilizando duas redes neurais recorrentes: a primeira rede neural é usada para modelar o caminho secundário para o ANC, enquanto a segunda rede é empregada para gerar o sinal de controle. Chang [14] propôs uma estrutura em redes neurais baseadas no algoritmo LMS filtrado, ou NFXLMS (Neural-based Filtered-X Least-Mean-Square algorithm), associado a um método para evitar a saturação prematura do algoritmo de treinamento backpropagation, utilizando a melhor taxa de ajustagem. Zhang [15] estudou um sistema ANC com não linearidades e propôs estruturas específicas em redes neurais para modelar a não-linearidade da propagação acústica da fonte primária no sistema. Bouchard [16] apresentou um procedimento para o desenvolvimento de um algoritmo baseado em LMS para a construção de um controlador usando rede neural. O principal critério de avaliação utilizado foi a carga computacional dos algoritmos visando a sua aplicação em sistemas multicanal de ANC.

Este artigo apresenta uma metodologia para a construção de uma ANN apta a ser executada em modo on-line na fase de operação de um sistema de ANC aplicado no controle da potência sonora em determinada região de um ambiente sujeito a uma fonte primária geradora de ruído por vibração (sistema vibro-acústico). A rede neural é treinada para fornecer a potência acústica em um ponto qualquer do espaço contido nesse sistema acústico, tendo como variáveis de entradas as coordenadas do ponto de interesse e o sinal de vibração coletado na fonte primária. A função objetivo usada no treinamento da rede é a soma ponderada dos quadrados dos erros (diferença entre o valor medido e o valor estimado pelo modelo para cada valor da saída). O método é testado e analisado em simulações feitas utilizando dados obtidos através de uma plataforma experimental.

2. MATERIAIS E MÉTODOS

2.1. Aparato experimental e metodologia para coleta de dados

O sistema vibro-acústico em estudo é composto por uma bomba centrífuga instalada em uma sala (Figura 1). A bomba centrífuga é acionada por um motor elétrico assíncrono e este conjunto é chamado de fonte primária de ruído. Nesse sistema são montados dois sensores ICP, um acelerômetro que mede a dinâmica gerada pela fonte primária e um microfone que mede a pressão sonora no interior da sala, em cada ponto de uma malha previamente definida. A Fig. (2) mostra detalhes da instalação do acelerômetro e do microfone.




Figura 1. Mapeamento de campo acústico gerado pela operação de uma bomba em uma sala fechada identificadas por coordenadas X, Y, Z: X = 1, 2, ..., 7 (0,44 m); Y = 1, 2, ..., 10 (0,44 m); e Z = 1, 2, ..., 5 (0,44 m): (a) Instalação experimental; (b) Deslocamento do microfone (sensor passivo) em malha de 350 pares padrões coletados (7x10x5 posições assumidas pelo sensor passivo).




Figura 2. Aparato experimental. (a) entrada do sistema (sensor instalado na fonte primária): acelerômetro da bomba (sensibilidade: 100 mV / g), (b) saída do sistema (sensor passivo): microfone (sensibilidade: 50 mV / PA).

Em cada medida realizada o microfone foi posicionado com seu eixo paralelo à parede (comprimento da sala) e ao plano do chão, em frente à bomba centrífuga. Os dados foram coletados por um coletor Microlog CMXA50 (SKF), que consiste em uma plataforma compacta para coleta de dados (dois canais em tempo real). O condicionamento do sinal coletado é feito por uma fonte ICP integrada a um filtro passa-banda (10-1000 Hz), com o ADC ajustado para uma taxa

de amostragem de 2560 Hz. O tempo de coleta para cada par entrada/saída foi estabelecido em 1.6 s. Como resultado dessas configurações, duas variáveis em forma de vetor (entrada u e saída y), cada uma composta de um conjunto de 4096 valores, foram coletadas, em tempo real, em cada ponto da grade de amostragem.

Considerando-se os dados coletados pelo acelerômetro instalado na bomba e variando-se a posição de um microfone por 350 pontos predefinidos na sala (identificados pelas suas coordenadas X, Y, Z: X = 1, 2, ..., 7 × 0,44 m; Y = 1, 2, ..., 10 × 0,44 m; e Z = 1, 2, ..., 5 × 0,44 m), foram coletados 350 pares padrões $\{u^p, y^p\}$ que representam a dinâmica da transmissão vibro-acústica entre o sinal de entrada proveniente do acelerômetro u e do sinal de saída proveniente do microfone y . O conjunto de pares coletados ($\{u^p, y^p\}$, $p = 1, 2, \dots, 350$) define o conjunto de padrões que será usado para treinamento de uma rede ANN recorrente que melhor possa descrever a dinâmica da transmissão vibro-acústica na plataforma experimental proposta.

Não foi analisada a influência do posicionamento do acelerômetro no processo identificado. O critério definido para escolha da posição e direção usadas para a fixação do acelerômetro foi o máximo nível global de vibração medido nos mancais do conjunto rotativo. Portanto, fixamos o acelerômetro no mancal do conjunto rotativo que apresentava o maior nível de vibração, mantendo-se essa posição constante durante todo o experimento. Não foi avaliada a possibilidade do acelerômetro ter sido posicionado sobre pontos nodais da estrutura e/ou estar medindo grandezas mecânicas que não são relevantes para a acústica do ambiente.

2.2. Estrutura do modelo: características da rede neural utilizada

As ANNs têm sido utilizadas para simular não linearidades de sistemas de natureza diversa em computadores digitais ou em placas de hardware. Neste trabalho foi utilizado como ponto de partida o modelo em uma ANN, introduzido por Rosenblatt [17] em 1958. De acordo com Másson [18], a topologia de uma rede neural artificial pode ser expressa através de um grafo dirigido com pesos $G = (V, A, W)$, onde V corresponde a um conjunto de vértices, A a um conjunto de arcos dirigidos e W a um conjunto de pesos para esses arcos. Cada vértice no grafo representa uma unidade de processamento. Uma unidade de processamento possui entradas u_1, u_2, \dots, u_R , que correspondem aos estados dos neurônios com os quais está conectada. A partir dessas entradas e do conjunto de pesos sinápticos $W_{1,1}, \dots, W_{1,R}$ é que se calcula o potencial do neurônio. Esse potencial é determinado por uma regra de propagação, que geralmente equivale à soma linear da multiplicação das entradas pelos pesos [18]. Uma rede com uma única camada possuindo S neurônios com uma função de ativação arbitrária e com R entradas é mostrada em detalhes na Fig. (3), que ilustra também a sua unidade de processamento.

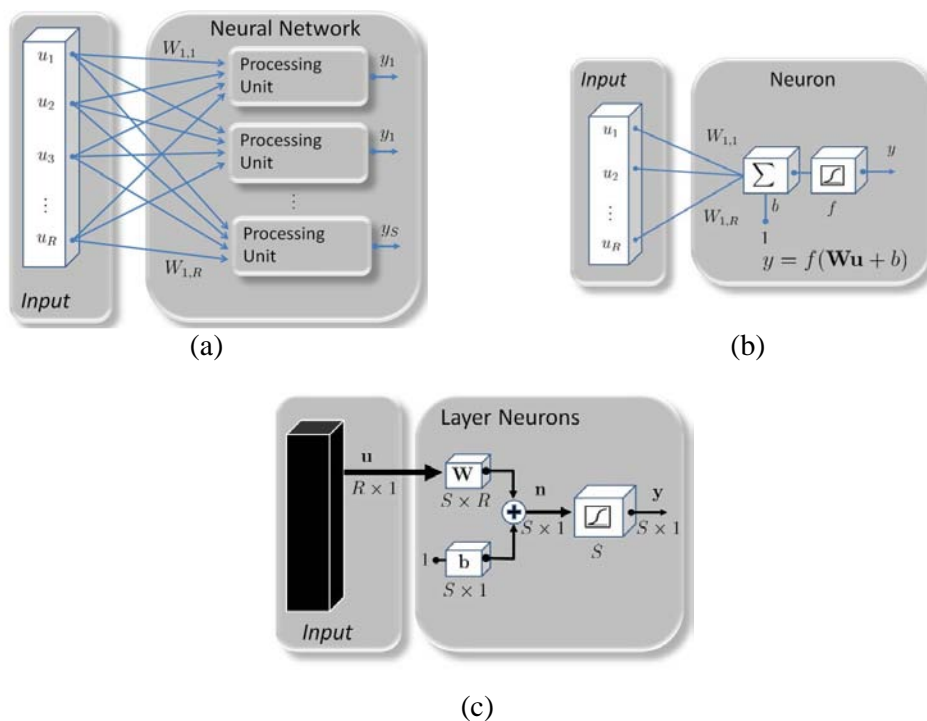


Figura 3. Rede neural com uma única camada (a), sua unidade de processamento (b) e seu diagrama (c).

Redes neurais freqüentemente possuem uma ou mais camadas ocultas de neurônios sigmóides (por exemplo, tansig ou logsig) seguidas por uma camada de saída de neurônios lineares. Redes com duas camadas:

- uma camada oculta com S_I neurônios sigmóide com tendências \mathbf{b}^1 (biases) associadas a cada neurônio;
- uma camada com S_L neurônios de saída ativada por uma função linear e com tendências \mathbf{b}^2 (biases) associadas a cada neurônio;

são capazes, usando-se o número suficiente de neurônios (S_I) na camada oculta, de aproximar qualquer função com um número finito de descontinuidades, dentro de uma precisão arbitrariamente especificada [19.20]. Essa estrutura é mostrada na Fig. (4) e pode ser usada como um aproximador universal de funções.

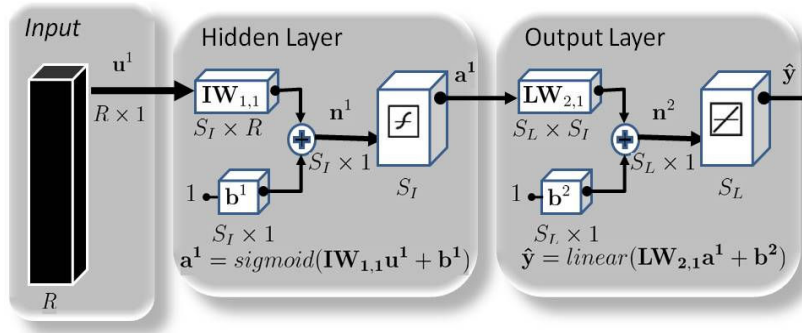


Figura 4. Diagrama da estrutura de uma rede com uma camada oculta com função sigmóide e uma camada de saída com função linear (aproximador universal de funções).

A representação da dinâmica do sistema foi caracterizada através da utilização de conjuntos de sinais de entradas e saídas do processo (u e y), atrasados no tempo, na entrada da ANN, conforme mencionado anteriormente [11,12], como mostra a Fig. (5), que ilustra também a estrutura interna da ANN adotada (uma camada intermediária e uma camada de saída), e onde $u(n)$ é a amostragem do sinal de entrada no instante n , $y(n)$ é a amostragem do sinal de saída no instante n , d é o atraso (tempo morto) da saída do sistema no que diz respeito à entrada u , $e(n)$ representa o erro de simulação e q é o operador de deslocamento no tempo. O esquema mostrado na Fig. (4) (aproximador geral de funções) é utilizado, e portanto essa ANN está apta, em princípio, a aproximar qualquer função com um número finito de descontinuidades usando-se um número suficiente de neurônios (S_I) na camada oculta.

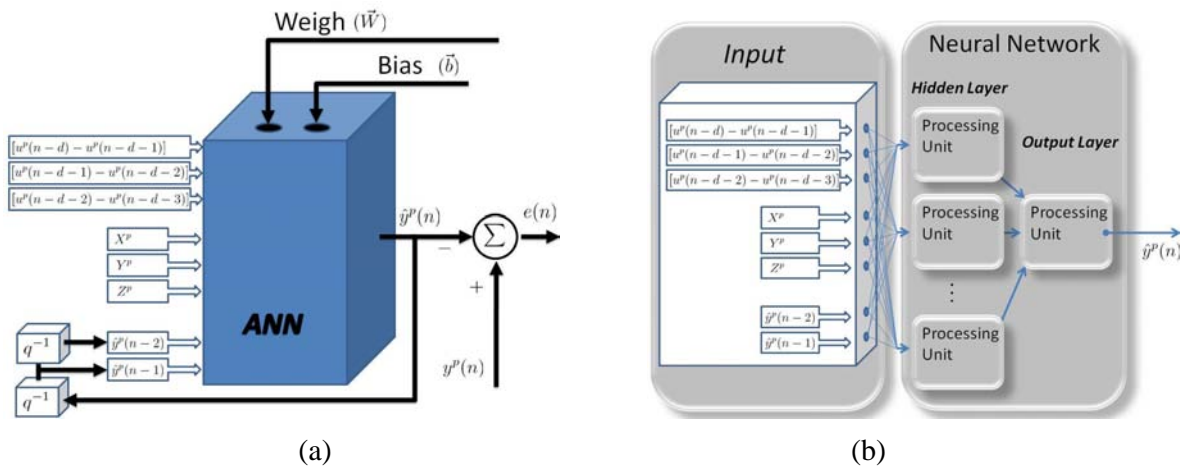


Figura 5. Estrutura ANN recorrente (predição de longo alcance) (a) e detalhe da estrutura interna adotada (b).

As ordens escolhidas para u e y na Fig. (5) são as mesmas adotadas no trabalho de Magalhães et al. [21]. Assim, considerando que as coordenadas X , Y e Z de um ponto qualquer da sala também são entradas para a rede (neste caso

estáticas, e portanto de ordem nula), pode-se concluir que a ANN dinâmica a ser configurada para estimar a pressão acústica $\hat{y}^p(n)$ em uma posição espacial arbitrária tem oito entradas. Para o atraso de tempo também é adotado o mesmo procedimento de Magalhães et al. [21], no qual d é calculado de forma teórica, utilizando a velocidade do som e a coordenada Y.

Magalhães et al. [21] apresentaram o desenvolvimento da função de transferência máquina-sala (Machine-Room Transfer Function - MRTF) que simula a transmissão acústica entre a fonte primária e um receptor em uma sala, compreendendo a distribuição espacial de 350 MRTFs (Machine-Room Transfer Functions) e um total de 1750 parâmetros. A fim de proporcionar a redução do número de parâmetros dos modelos utilizados para descrição do comportamento espacial do sistema acústico, foi aplicado um processo de interpolação sobre um subconjunto dos modelos identificados. Esse procedimento resultou em um modelo com 135 parâmetros, uma redução significativa (cerca de 93%) do número total de parâmetros, mantendo uma boa descrição da dinâmica dominante do sistema, sem que houvesse uma degradação do sinal de saída. Esta redução permite uma futura implementação dessa estrutura de modelo em sistemas de controle em tempo real (real time).

Para efeito de uma avaliação comparativa entre os resultados obtidos com a estrutura aqui proposta e os resultados obtidos no trabalho de Magalhães et al. [21], foi estabelecido que o número máximo de parâmetros a serem utilizados na rede proposta nesse trabalho deveria ser inferior a 135 (número de parâmetros adotado na estrutura proposta no trabalho de Magalhães et al. [21]). Para atender a esse requisito, foi adotado $N_p \approx 80$. O número total de parâmetros em uma ANN (Figura 4) com uma camada oculta (intermediária) e um neurônio na camada de saída é dado por:

$$N_p = RS_1 + 2S_1 + 1, \quad (1)$$

onde R é o número de entradas da rede e S_1 é o número de neurônios da camada oculta. Assim, considerando as condições específicas previamente estabelecidas ($R=8$ e $N_p \approx 80$) na Equação (1), chega-se ao valor $S_1 = 8$ (número de neurônios da camada oculta).

2.3. Procedimento de estimação dos parâmetros: treinamento da rede recorrente

Definida a topologia da rede, é necessário estabelecer o procedimento de treinamento, que foi formulado através do procedimento de otimização ilustrado na Fig. (6)

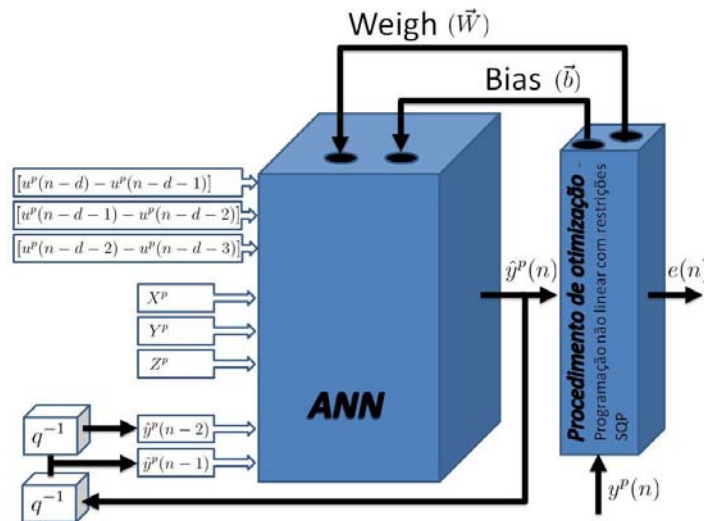


Figura 6. Treinamento ANN recorrente (predição de longo alcance).

Desta forma, o treinamento da rede foi formulado como um problema genérico de otimização (PGO) não linear com restrições:

$$\begin{aligned} & \min_{\mathbf{x}} f(\mathbf{x}) \\ & \text{Sujeito a} \\ & G_i(\mathbf{x}) = 0, \quad i = 1, \dots, m_e \\ & G_i(\mathbf{x}) \leq 0, \quad i = m_e + 1, \dots, m \end{aligned} \quad (2)$$

onde \mathbf{x} é o vetor de parâmetros de comprimento n , $f(x)$ é a função objetivo, que retorna um valor escalar, e a função do vetor $G(x)$ retorna um vetor de comprimento m contendo os valores das igualdades e das desigualdades (restrições) avaliadas em x .

Para a solução destes problemas, métodos de otimização ue se baseiam no atendimento às condições de Kuhn-Tucker (KT) [22] são mais eficientes do que métodos que transformam um problema com restrições em um problema sem restrições, usando uma função de penalidade para soluções próximas às restrições ou além de seus limites. As soluções das equações de KT constituem a base para muitos algoritmos de programação não linear. Estes algoritmos visam calcular os multiplicadores de Lagrange diretamente. Os métodos que usam esses algoritmos são comumente referidos como métodos Sequential Quadratic Programming (SQP). Os métodos SQP descritos nos trabalhos de Biggs [23], Han [24] e Ge e Powell [25], apresentam uma metodologia adequada para a solução do problema de otimização da ANN dinâmica. A SQP permite simular o método de Newton para otimização com restrições, justamente como seria feito para otimização sem restrições. Em cada iteração principal, uma aproximação é feita para a Hessiana da função Lagrangiana usando um método quase-Newton. Essa é então utilizada para gerar um subproblema de Quadratic Programming (QP), cuja solução é usada para definir a direção de busca do melhor valor. Uma visão geral do SQP pode ser encontrada em Hock e Schittkowski [26].

Neste trabalho foi utilizado o método SQP implementado na função “fmincon” do MATLAB®. Uma condição importante para o sucesso na resolução destes problemas é a disponibilidade de uma boa estimativa inicial. Neste caso, foi utilizado como chute inicial o modelo treinado conforme o esquema mostrado na Fig. (7), que utiliza o conjunto de padrões formado pelos pares coletados no experimento ($\{u^p, y^p\}$, $p=1,2,\dots,350$), que define o vetor de entrada para cada instante n , conforme definição dada pela Equação (3). O resultado desse treinamento é uma rede capacitada para “predição um passo a frente”, que não é a rede final de interesse, pois é desejada uma rede com “predição de longo alcance” (Figura 6), mas fornece uma boa estimativa inicial para o procedimento de otimização ilustrado na Fig. (6). No procedimento de otimização aqui utilizado (Figura 6 e Figura 7), a função objetivo usada no treinamento das redes é a soma ponderada dos quadrados dos erros (diferença entre o valor medido e o valor estimado pelo modelo para cada valor da saída, dado por $e(n)$), para $n=1,\dots, 350$.

$$Entrada(n) = \begin{matrix} [u^p(n-d) - u^p(n-d-1)] \\ [u^p(n-d-1) - u^p(n-d-2)] \\ [u^p(n-d-2) - u^p(n-d-3)] \\ X^p \\ Y^p \\ Z^p \\ y^p(n-2) \\ y^p(n-1) \end{matrix} \Bigg|_{p=1}^{350} \quad (3)$$




Figura 7. Treinamento ANN (predição um passo a frente).

3. RESULTADOS E DISCUSSÃO

O modelo resultante foi usado para prever o comportamento dinâmico e espacial do sinal de saída do sistema (microfone). Nas Fig. (8) a (10) podem ser vistos o melhor e o pior resultados do modelo na estimativa do sinal de saída para os planos Z=1, 3 e 5, assim como uma comparação qualitativa com os resultados estimados com os modelos

obtidos no trabalho de Magalhães et al. [21]. É possível observar que mesmo os piores resultados com os modelos ANN fornecem uma representação adequada da dinâmica dos dados experimentais, capturando as principais tendências de comportamento do sistema, embora com uma forte atenuação das amplitudes em frequências superiores, como pode ser visto na Fig. (11), que apresenta a média da PSD (Power Spectral Density) para os 350 pontos de malha. O modelo ANN fornece uma boa descrição da dinâmica dominante do sistema (picos do PSD, onde a maioria da energia do sinal está concentrada).

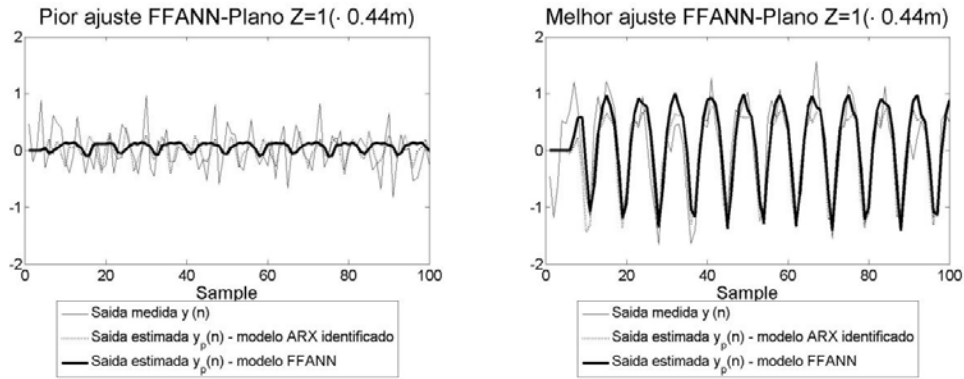


Figura 8. Melhores e piores ajustes do modelo para o plano Z = 1 (0,44 m): resposta no tempo para o modelo ARX identificado e para o modelo ANN.

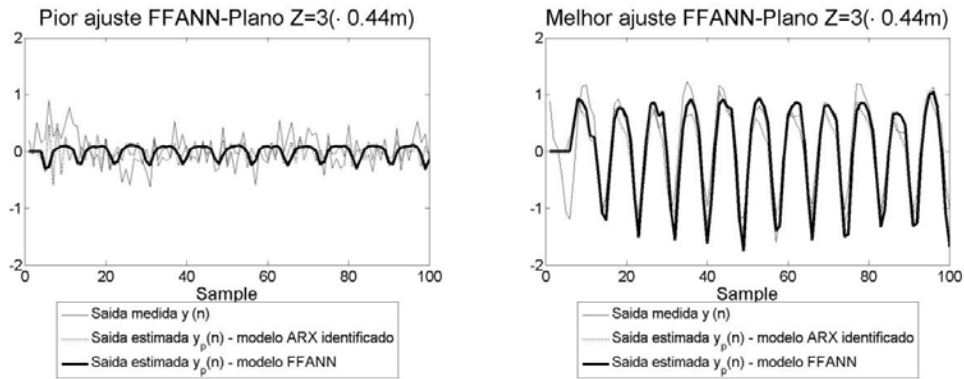


Figura 9. Melhores e piores ajustes do modelo para o plano Z = 3 (0,44 m): resposta no tempo para o modelo ARX identificado e para o modelo ANN.




Figura 10. Melhores e piores ajustes do modelo para o plano Z = 5 (0,44 m): resposta no tempo para o modelo ARX identificado e para o modelo ANN.

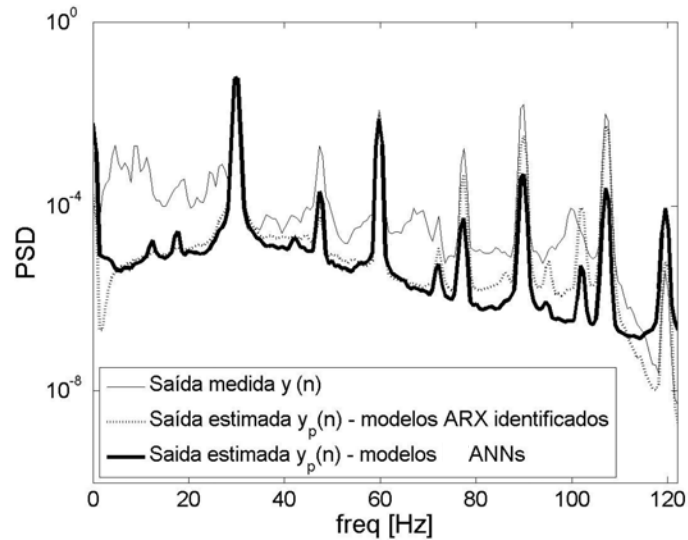


Figura 11. Média PSD para o sinal de saída do sistema (microfone).

A Tab. (1) compara o resultado obtido com a aplicação das diversas estruturas de modelo propostas nesse trabalho, incluindo os resultados obtidos no trabalho de Magalhães et al. [21]. Observando os resultados é fácil concluir que:

- Menores erros são obtidos quando se considera os atrasos em cada plano XZ na identificação dos modelos nos diversos pontos da grade coletada;
- Segundo os resultados obtidos no trabalho de Magalhães et al. [21], a maior redução possível da malha para aplicação da interpolação foi a redução para 36 MRTFs. Como é possível ver na Tabela 1, qualquer redução superior a essa leva os valores médio, mínimo ou máximo da norma do erro para valores superiores aos respectivos valores da norma euclidiana do sinal experimental;
- O modelo ANN apresentou desempenho equivalente ao modelo ARX (36 MRTFs, 135 parâmetros), com a vantagem de utilizar um número menor de parâmetros (80 parâmetros).

4. CONCLUSÕES

Este artigo apresentou o desenvolvimento de um modelo baseado em *Artificial Neural Networks* (ANN) para descrever a transmissão vibro-acústica entre a fonte primária de ruído e um receptor em uma sala. O modelo ANN dinâmico capturou a principal dinâmica do sistema, e apresentou um desempenho equivalente ao desempenho apresentado pelo modelo ARX interpolado [21], mas com um número menor de parâmetros. Considerando-se que essas duas estruturas de modelos têm um número total de parâmetros diferente, o modelo ANN dinâmico apresentou uma melhor aderência aos dados experimentais, obtendo uma menor variação dos erros na estimativa da saída do sistema (Tabela 1). É possível melhorar o desempenho do modelo ANN dinâmico, mas para isso é necessária uma mudança na estrutura proposta para esse modelo, como, por exemplo, o aumento do número de neurônios na camada oculta. Ações como essa, no entanto, levariam ao aumento do número de parâmetros do modelo, exigindo um maior esforço computacional para simulação das saídas do sistema. Como o objetivo último desse artigo é o desenvolvimento de modelos tridimensionais que possam ser utilizados na construção de sistemas para Active Noise Control (ANC), que tenham a capacidade de simular de forma apropriada (qualitativa e quantitativamente) a dinâmica de sistemas vibro-acústicos, com baixo custo computacional, esta nova estrutura perderia nesse requisito.

Tabela 1. Comparação da norma euclidiana dos erros

Modelos:	Norma Euclidiana do Erro:	Média	Mínimo	Máximo	Número de Parâmetros
Norma Euclidiana do Sinal de Saída		11.8	4.9	21.6	
ARX identificado sem atraso (350 MRTFs)		7.3	3.6	15.8	1750
ARX identificado com atraso (350 MRTFs)		7.1	4.1	13.3	1750
ARX interpolado com atraso (36 MRTFs)		9.3	4.6	20.8	135
ARX interpolado com atraso (18 MRTFs)		9.8	4.6	22.0	90
ARX interpolado com atraso (9 MRTFs)		10.8	5.0	19.9	35
ARX interpolado com atraso (4 MRTcFs)		11.0	5.0	19.9	20
ANN com atraso		9.3	4.9	16.7	80

5. AGRADECIMENTOS

Os autores agradem a CAPES e ao CNPq pelo suporte financeiro.

6. REFERÊNCIAS

- [1] Kachanov, B.O.; Symmetric Laplace transform and its application to parametric identification of linear systems. *AUTOMATION AND REMOTE CONTROL*, 70(8):1309-1316, 2009.
- [2] Hines, E.L.; Llobet, E.; Gardner, J.W.; Electronic noises: a review of signal processing techniques. *IEE PROCEEDINGS-CIRCUITS DEVICES AND SYSTEMS*, 146(6): 297-310, 1999.
- [3] Becerra V.M.; Garces F.R.; Nasuto S.J.; Holderbaum W.; An efficient parameterization of dynamic neural networks for nonlinear system identification. *IEEE TRANSACTIONSON NEURAL NETWORKS*, 16: 983-988, 2005.
- [4] Madár J.; Abonyi J.; Szeifert F.; Genetic programming for the identification of nonlinear input-output models. *INDUSTRIAL AND ENGINEERING CHEMISTRY RESEARCH*, 44: 3178-3186, 2005.
- [5] Prasad V.; Bequette B.W.; Non linear system identification and model reduction using artificial neural networks. *COMPUTERS AND CHEMICAL ENGINEERING*, 27: 1741-1754, 2003.
- [6] Siniscalchi, S.M.; Lee, C.; A study on integrating acoustic-phonetic information into lattice rescoring for automatic speech recognition. *SPEECH COMMUNICATION*, 51(11):1139-1153, 2009.
- [7] Yu, L.; Kang, J.; Modeling subjective evaluation of soundscape quality in urban open spaces: An artificial neural network approach. *JOURNAL OF THE ACOUSTICAL SOCIETY OF AMERICA*, 126(3):1163-1174, 2009.
- [8] Dariouchy, A.; Aassif, E.; Maze, G.; Decultot, D.; Mouddeu, A.; Prediction of the acoustic form function by neural network techniques for immersed tubes. *JOURNAL OF THE ACOUSTICAL SOCIETY OF AMERICA*, 124 (2): 1018-1025, 2008.
- [9] Saxena, A.; Saad, A.; Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems. *APPLIED SOFT COMPUTING*, 7 (1): 441-454, 2007.
- [10] Tsoi, A.C.; Back, A.D.; Locally recurrent globally feedforward networks: A critical review of architectures. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 5(2):229-239, 1994.
- [11] Levin U.; Narendra K. S.; Control of nonlinear dynamic systems using neural networks-controllability and stabilization. *IEEE TRANS. ON NEURAL NETWORKS*, 4(2): 192-206, 1993.
- [12] Levin U.; Narendra K.S.; Control of nonlinear dynamical systems using neural networks - observability, identification and control. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 7(1):30-42, 1996.
- [13] Bambang, R.T.; Adjoint EKF learning in recurrent neural networks for nonlinear active noise control. *APPLIED SOFT COMPUTING*, 8 (4): 1498-1504, 2008.
- [14] Chang, C.Y. and Luoh, F.B.; Enhancement of active noise control using neural-based filtered-X algorithm. *JOURNAL OF SOUND AND VIBRATION*, 305 (1-2): 348-356, 2007.

- [15] Zhang, Q.Z.; Gan, W.S. and Zhou, Y.; Adaptive recurrent fuzzy neural networks for active noise control. JOURNAL OF SOUND AND VIBRATION, 296 (4-5): 935-948, 2006.
- [16] Bouchard, M.; New recursive-least-squares algorithms for nonlinear active control of sound and vibration using neural networks. IEEE TRANSACTIONS ON NEURAL NETWORKS, 12 (1): 135-147, 2001.
- [17] Rosenblatt, F.; THE PERCEPTRON - A Probabilistic Model for Information-Storage and Organization in the Brain. PSYCHOLOGICAL REVIEW, 65 (6): 386-408, 1958.
- [18] Masson, E; Wang, Y.; Introduction to Computation and Learning in Artificial Neural Networks. EUROPEAN JOURNAL OF OPERATIONAL RESEARCH, 47 (1): 1-28, 1990.
- [19] Meade, A.J.; Sonneborn, H.C.; Numerical solution of a calculus of variations problem using the feedforward neural network architecture. ADVANCES IN ENGINEERING SOFTWARE, 27 (3): 213-225, 1996.
- [20] Selmic, R.R.; Lewis, F.L.; Neural-network approximation of piecewise continuous functions: Application to friction compensation. IEEE TRANSACTIONS ON NEURAL NETWORKS, 13 (3): 745-751, 2002.
- [21] Magalhães, R.S.; Santos, J.M.C.; Fontes, C.O.H.; Almeida, L.A.L.; Embiruçu, M.; A Model for Three-Dimensional Simulation of Acoustic Emissions from Rotating Machine Vibration. JOURNAL OF THE ACOUSTICAL SOCIETY OF AMERICA, accepted, 2010.
- [22] Brezhneva, O.A.; Tret'yakov, A.A.; Wright, S.E.; A simple and elementary proof of the Karush-Kuhn-Tucker theorem for inequality-constrained optimization. OPTIMIZATION LETTERS, 3 (1): 7-10, 2009.
- [23] Biggs, M.C.; Convergence of Some Constrained Minimization Algorithms Based on Recursive Quadratic Programming. JOURNAL OF THE INSTITUTE OF MATHEMATICS AND ITS APPLICATIONS, 21 (1): 67-81, 1978.
- [24] Han, S.P.; Globally Convergent Method for Nonlinear-Programming. JOURNAL OF OPTIMIZATION THEORY AND APPLICATIONS, 22 (3): 297-309, 1977.
- [25] Ge, R.P.; Powell, M.J.D.; The Convergence of Variable-Metric Matrices in Unconstrained Optimization. MATHEMATICAL PROGRAMMING, 27 (2): 123-143, 1983.
- [26] Hock, W.; Schittkowsky, K.; A Comparative Performance Evaluation of 27 Non-Linear Programming Codes. COMPUTING, 30 (4): 335-358, 1983.

7. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

IDENTIFICATION OF ARTIFICIAL NEURAL NETWORK MODELS FOR THREE-DIMENSIONAL SIMULATION OF A VIBRATION-ACOUSTIC DYNAMIC SYSTEM

Magalhães, Robson da Silva, RobsonM@cimatec.fieb.org.br¹

Fontes, Cristiano H. O, cfontes@ufba.br²

Almeida, Luiz A. L, lalberto@ufba.br²

Embiruçu, Marcelo, embirucu@ufba.br²

¹SENAI - CIMATEC,

²UFBA - Universidade Federal da Bahia.

Resumo: *This paper proposes a model structure based on a Artificial Neural Network (ANN) for the dynamic modeling of the acoustic transmission between a primary source that is closed in a room and a positioned receiver at any point within this room. This model is based on neural networks that are trained by a BackPropagation (BP) algorithm and it should describe the behavior of the investigated process; so it should be a model for the three-dimensional simulation of acoustic emissions, which were originated from the vibration of a machine.*

In the identification of the system's dynamic a MISO (Multi-Input Single-Output) model structure is used. The results show that the obtained model is consistent and adequately describes the main dynamics of the studied phenomenon, showing that the MISO approach, using a ANN, is appropriate for the simulation of the investigated process and the proposed structure of the dynamic model is promising, considering its future application in systems for Active Noise Control (ANC).

Palavras-chave: *Neural networks, Nonlinear identification, Dynamic models, Distributed parameter systems, Vibrate-acoustic systems.*