

Simulador de Ruído de Cavitação de Embarcações utilizando uma Rede Neural Realimentada

Anderson Damacena Santos, Elio P. Sarno Filho,
Eduardo F. Simas Filho e Antônio C. L. Fernandes Jr.
*Program in Electrical Engineering
Federal University of Bahia
Salvador, Brasil
(anderson.damacena,elio.pithon,antonio.lobes)@ufba.br*

José M. de Seixas
*Signal Processing Laboratory
Federal University of Rio de Janeiro
Rio de Janeiro, Brasil
seixas@lps.ufrj.br*

Resumo—Sistemas de sonar passivo são utilizados tanto em aplicações civis quanto militares, para tarefas como monitoramento do ambiente submarino e detecção de animais e embarcações. A aquisição de sinais acústicos submarinos requer um complexo sistema de medição e envolve custos consideráveis para instalação e manutenção. Aliado a isso, a grande variedade de classes de embarcação e condições climáticas aumenta consideravelmente a diversidade destes tipos de sinais. Neste contexto, esse trabalho propõe-se a desenvolver um simulador de sinais acústicos submarinos que combina informações da cavitação de embarcações com ruído ambiente a partir de um sistema com um bloco fenomenológico e um bloco baseado em aprendizado de máquinas. O primeiro produz a combinação de ruído de cavitação de embarcações com ruído ambiente a partir da descrição dos fenômenos físicos utilizando modelos matemáticos. A seguir, uma rede neural realimentada (estrutura NARX) é utilizada para produzir um mapeamento que aproxima o resultado do simulador do comportamento de sinais experimentais. O simulador proposto foi capaz de produzir sinais com grande fidedignidade a sinais reais.

Index Terms—Rede Neural, Rede NARX, Simulador, Sonar Passivo

I. INTRODUÇÃO

Nas últimas décadas houve um aumento considerável na utilização de sistemas sonar (*Sound navigation and ranging*) no âmbito submarino [1]. É possível encontrar aplicações em diversas áreas como, por exemplo, detecção e monitoramento de peixes e animais mamíferos usando sonar de imagem [2], detecção de alvos em ambiente subaquático [3] e detecções de danos em estruturas subaquáticas [4].

Sistemas sonar submarinos são classificados em dois tipos, ativos e passivos [5]. Sonares ativos têm como característica a emissão de um pulso que, ao refletir em algum obstáculo, retorna para a fonte de origem, permitindo assim a detecção, localização e classificação do alvo. Sonares ativos comumente são utilizados em aplicações civis. O sonar passivo é voltado para a detecção e monitoramento de um alvo, a principal característica desse tipo é a não emissão de sinal. Para a detecção do alvo de interesse o mesmo se aproveita do fato de que o alvo se comporta como uma fonte emissora de sinais acústicos, sinais esses que irão se propagar pelo meio aquático, chegando nos receptores do sonar. O Sonar passivo é fundamental para operações de submarinos militares.

Um dos problemas encontrados ao trabalhar com sonar passivo é a dificuldade de obtenção de dados experimentais. Devido à escassez de dados relacionados à ruídos acústicos submarinos, usualmente pesquisadores precisam criar seu próprio banco de dados, fazendo com que o investimento seja dispendioso, pois, é necessário empregar diversas pessoas, equipamentos e a instalação desses equipamentos. Associado a isso há dificuldade de garantir a condição ambiental no momento da aquisição dos dados.

Outro problema identificado, ao se trabalhar com sonar passivo é que, em condições reais, o sinal de interesse está contaminado por diversas fontes de ruído, tanto ambientais, quanto irradiadas por outras fontes. O ruído ambiente é proveniente de fontes naturais (ruído da chuva, estado do mar, fontes biológicas) [6] e fontes antropogênicas (ruído de tráfego marítimo e exploração de gás e óleo) [7]. O ruído irradiado é proveniente da vibração das máquinas e do equipamento de propulsão das embarcações [5]. Muitas vezes o ruído tem espectro de frequência similar ao sinal produzido pelo alvo de interesse. Uma forma de contornar essa limitação é a utilização de técnicas de processamento de sinais com o objetivo de realizar a separação do sinal de interesse dos ruídos [8].

Uma das técnicas de processamento de sinais voltadas para o sonar passivo é a análise DEMON (*Demodulation of envelope modulation on noise*), que é um analisador espectral de banda estreita que trabalha sobre o ruído de cavitação [9], ruído gerado pela rotação do hélice da embarcação. A partir da análise do sinal acústico irradiado das embarcações é possível determinar a velocidade de rotação do eixo do hélice e a quantidade de pás da embarcação de interesse [10], permitindo, assim, a localização e classificação das embarcações.

O processamento para extração de informações é uma parte importante em um sistema sonar. Usualmente feita de forma automática, os módulos de processamento digital ajudam o operador sonar a tomar decisões relacionadas à caracterização da embarcação. Além das informações fornecidas pelos módulos de processamento, o operador sonar pode realizar análises através do áudio do sinal, essa técnica é usada pelo operador com o intuito de auxiliar a identificação das embarcações e para estimar a sua velocidade [11] [12].

Neste contexto, devido à dificuldade de obtenção de dados

experimentais relacionados a ruídos acústicos submarinos, o presente artigo propõe desenvolver um modelo baseado em conceitos estatísticos e de aprendizado de máquinas. O objetivo é desenvolver um simulador de diferentes tipos de ruídos irradiados de embarcações (ruído de cavitação) em diferentes condições de operação, permitindo assim que a comunidade científica possa adquirir dados, de forma sintética, para o desenvolvimento de soluções em diferentes situações como, por exemplo, validação de técnicas de processamento de sinais de sonar passivo. A Fig. 1 apresenta o diagrama de blocos do modelo proposto, o sistema é constituído por um simulador fenomenológico e uma rede neural.

O simulador fenomenológico é composto por dois módulos de simulação distintos, onde cada módulo é responsável por gerar um determinado tipo de ruído acústico submarino. O sistema tem como intuito gerar sinais simulados de ruído ambiente (ruído estado do mar e chuva) e ruído irradiado (cavitação), onde será possível determinar certas características do sinal a ser gerado como, por exemplo, tipo de ruído ambiente e sua intensidade, e características da embarcação.

Após a geração do ruído, o sinal proveniente do simulador fenomenológico será utilizado como entrada para a rede neural NARX (*nonlinear autoregressive network with exogenous inputs*). O intuito é utilizar a rede NARX para incorporar as características não-lineares presentes nos sinais experimentais, permitindo assim que o simulador de ruídos acústicos submarinos gere sinais mais realistas.

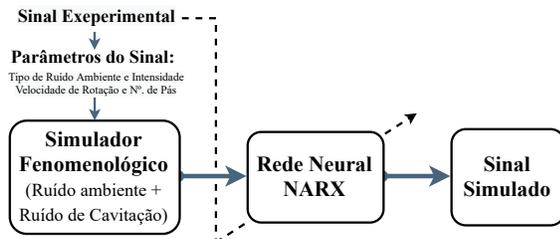


Figura 1: Diagrama de blocos simplificado do simulador acústico.

II. FUNDAMENTAÇÃO TEÓRICA

A. Acústica Submarina

No ambiente acústico submarino existem diversas fontes de ruídos, que podem ser classificadas em duas categorias: ruído irradiado e ruído ambiente [5]. A Fig. 2 demonstra alguns exemplos de ruídos submarinos.

Como o próprio nome diz, o ruído ambiente é proveniente de fontes naturais presentes no ambiente no qual o sonar está localizado. Entre as principais fontes de ruído acústico ambiente, pode-se destacar: estado do mar e chuva [1].

O ruído estado do mar é um ruído proveniente da incidência do vento na superfície do oceano e da quebra das ondas [5], tendo comportamento espectral passa-baixa, ver Fig. 3a. O ruído pode ser classificado em 7 níveis de intensidade, cada um deles está associado à altura das ondas e velocidade do vento.

Já o ruído da chuva é gerado pelo impacto das gotas da chuva na superfície do oceano [5], com comportamento similar

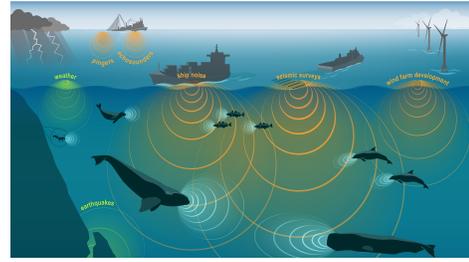


Figura 2: Exemplos de ruídos acústico submarino, adaptado de [13].

a um passa-faixa não simétrico, ver Fig. 3b. O ruído da chuva pode ser classificado em quatro níveis de intensidade, cada nível está relacionado à taxa de precipitação da chuva.

É importante ressaltar que o ruído ambiente é, em geral, prejudicial ao sistema sonar pois pode prejudicar a detecção dos sinais de interesse [14] [15].

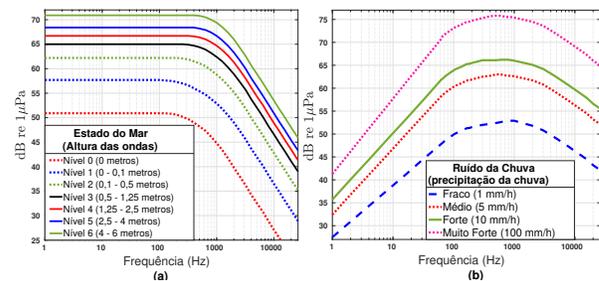


Figura 3: Ruído Ambiente: (a) estado do mar (b) chuva.

O ruído irradiado é proveniente de fontes artificiais, como, por exemplo, submarinos, navios e plataformas para extração de petróleo. Entre os ruídos, pode-se destacar o ruído de cavitação do hélice.

O ruído de cavitação é um ruído proveniente da rotação do hélice da embarcação. Quando o hélice está em funcionamento, ocorre uma redução de pressão, fazendo com que o líquido ao redor evapore formando bolhas de diferentes tamanhos, que irão explodir e implodir, gerando assim um ruído característico. O ruído de cavitação é um sinal modulado em amplitude formado por um sinal de banda estreita (tons espectrais) e banda larga (espectro contínuo).

O ruído de banda estreita é um sinal composto por tons espectrais. Situado abaixo de 1 kHz, o ruído está relacionado às características da embarcação, onde, a partir da análise espectral do ruído, é possível estimar algumas características, como, por exemplo, a velocidade de rotação do hélice e a quantidades de pás.

Por sua vez, o ruído de espectro contínuo é gerado a partir do colapso das bolhas de ar formadas a partir da rotação do hélice da embarcação. A banda de frequência do ruído de espectro contínuo vai desde 1 Hz a 20 kHz, tendo amplitude máxima em torno de 100 Hz. Para a banda de frequência de 1 a 100 Hz, o espectro tem um acréscimo entre 6dB/oitava e 12dB/oitava. Já para a banda de frequência superior a 100 Hz,

o espectro de frequência tem um declive de $-6\text{dB}/\text{oitava}$. O ruído de banda larga tem comportamento gaussiano colorido.

B. Análise DEMON

A análise DEMON é um analisador de banda estreita que trabalha sobre o ruído de cavitação. O intuito é, a partir da análise do sinal acústico irradiado, obter informações relacionadas à velocidade de rotação do eixo do hélice e o número de pás da embarcação. A Fig. 4 apresenta um exemplo da análise Demon de uma embarcação hipotética. O número de harmônicos está relacionado à quantidade de pás do hélice, enquanto a frequência de rotação do eixo do hélice é dada pelo primeiro harmônico do espectro.

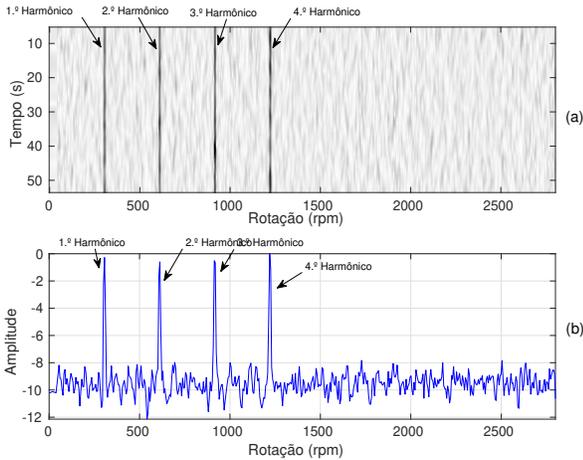


Figura 4: Análise Demon: (a) demograma, (b) espectro médio.

A Fig. 5 mostra o diagrama de blocos da análise DEMON. Inicialmente, o ruído é filtrado utilizando um filtro passa faixa (FPF) com o objetivo de limitar o sinal à banda de frequência mais característica do ruído de cavitação. Uma vez que a frequência de amostragem do sinal é maior que a banda de frequência preservada pelo FPF, após a filtragem é feita uma subamostragem do sinal. Em seguida, o sinal é demodulado para desfazer a modulação em amplitude que ocorre no processo de geração do ruído de cavitação. Com o intuito de obter as informações referentes à velocidade da embarcação, é aplicada a Transformada de Fourier de tempo curto (STFT - *Short-time Fourier transform*), obtendo assim o espectro de frequência do sinal demodulado. Após a STFT, o sinal é normalizado e apresentado.

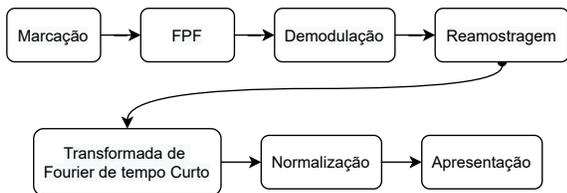


Figura 5: Diagrama de blocos da análise DEMON, Elaborada pelo autor.

C. Rede Neural NARX

Com o crescimento das pesquisas relacionadas às redes neurais artificiais novas arquiteturas foram desenvolvidas e uma arquitetura que se destaca são as redes recorrentes (*recurrent neural network* - RNN). As redes recorrentes se distinguem das demais redes neurais pelo fato de ter pelo menos um laço de realimentação [16]. As RNN são voltadas para o reconhecimento de padrões em seqüências de dados. Por considerar o tempo e a seqüência do sinal a arquitetura torna-se viável para trabalho com processos estocásticos, tanto para sistemas de tempo contínuo quanto para tempo discreto [17].

A arquitetura NARX (*Nonlinear autoregressive with exogenous inputs*) é uma rede neural recorrente dinâmica comumente usada na modelagem de processos estocásticos [18]. Baseada em uma rede *perceptron* multicamadas, o modelo NARX possui múltiplas entradas e realimentação de sua saída para a entrada, ver Fig. 6. Tanto a entrada quanto a saída realimenta sofrem atrasos na composição do vetor de entrada.

Considerando a Fig. 6, a rede NARX é descrita por (1) onde $x[n]$ e $y[n]$ são, respectivamente, a entrada e a saída do sistema em intervalos de tempo discreto n , $n_i \geq 1$ e $n_j \geq 1$ são os atrasos de unidade de tempo de entrada e saída, respectivamente e φ é a função de entrada-saída da rede.

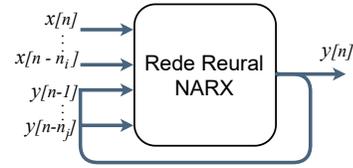


Figura 6: Rede recorrente NARX, Elaborada pelo autor.

$$y[n] = \varphi [y[n - 1], \dots, y[n - n_j], x[n], \dots, x[n - n_i]] \quad (1)$$

III. SIMULADOR PROPOSTO

Para a modelagem dos ruídos ambiente estado do mar e chuva, admitindo que os mesmos tenham distribuição Gaussiana [5], adotou-se modelo proposto na Fig. 7, onde $x[n]$ é um ruído gaussiano branco, $h[n]$ a resposta ao impulso do sistema linear e invariante no tempo (LIT) e $y[n]$ ruído gaussiano colorido.

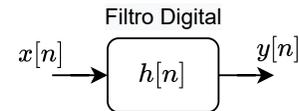


Figura 7: Diagrama de blocos para o sistema proposto.

O modelo proposto tem como finalidade gerar em sua saída um sinal com densidade espectral de potência desejada (PSD - *power spectral density*). Uma vez que a PSD de um ruído gaussiano branco é constante para toda banda de frequência, é possível obter um ruído gaussiano colorido com PSD específica fazendo com que o ruído branco seja filtrado por um filtro digital linear.

É mostrado em (2) que a PSD da saída de um sistema LTI, $S_y(e^{j\omega})$, pode ser obtida a partir da multiplicação da PSD do sinal de entrada, $S_x(e^{j\omega})$, pelo módulo da resposta em frequência do filtro, $|H(e^{j\omega})|^2$. O sistema tem como base a característica de que, em uma transformação linear de um processo dito gaussiano, o resultado produzirá uma saída Gaussiana [19].

$$S_y(e^{j\omega}) = S_x(e^{j\omega}) |H(e^{j\omega})|^2 \quad (2)$$

A partir de (2), considerando que a PSD de saída, $S_y(e^{j\omega})$, é conhecida e fazendo com que $S_x(e^{j\omega})$ constante para toda banda de frequência ω de interesse, pois $x[n]$ é um ruído branco de banda limitada, é possível determinar a magnitude da resposta em frequência para o filtro $|H(e^{j\omega})|$ a partir de (3).

$$|H(e^{j\omega})| = \sqrt{\frac{|S_y(e^{j\omega})|}{|S_x(e^{j\omega})|}} = \sqrt{|S_y(e^{j\omega})|} \quad (3)$$

Para estimar $|H(e^{j\omega})|$, foram utilizados os pares $|S_y(e^{j\omega_i})|$ e ω_i obtidos de [5]. Uma vez que $S_x(e^{j\omega})$ de um ruído branco é constante para toda banda de frequência de interesse, sem perda de generalidade, neste trabalho, foi adotado $|S_x(e^{j\omega})| = 1$.

Já o ruído de cavitação, de acordo com [5] é um ruído modulado em amplitude, definido por (4) onde, $S[n]$ é um ruído de banda larga, $A[n]$ é um ruído de banda estreita e α o índice de modulação [1], a Fig. 8 apresenta o diagrama de blocos da modulação em amplitude do ruído.

$$G[n] = [1 + \alpha A[n]] S[n]. \quad (4)$$

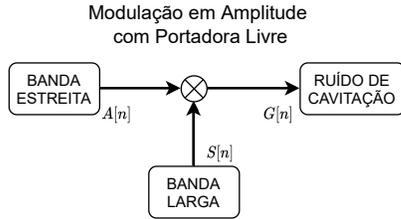


Figura 8: Diagrama de blocos da modulação em amplitude.

Para a obtenção do ruído de banda larga, adotando o modelo da Fig. 7, onde $y[n] = S[n]$, um ruído gaussiano branco $x[n]$ será filtrado por um filtro $h[n]$, gerando na saída do sistema o ruído de banda larga $S[n]$. Para estimar $|H(e^{j\omega})|$ da resposta em frequência do filtro, foram utilizadas as informações espectrais do ruído de banda larga apresentada em [20].

O ruído de banda estreita é composto a partir de tons espectrais de frequência situados abaixo de 1 kHz, ver (5), onde f_{sh} é a frequência de rotação do eixo, H é o número de harmônicos (número de pás) e A_n é a amplitude de cada harmônico.

$$A[n] = \sum_{h=1}^H A_n \cos(2\pi h f_{sh} n) \quad (5)$$

Após a modelagem do simulador fenomenológico, foi implementada a rede NARX. O ruído gerado pelo simulador fenomenológico será usado como entrada para a rede. O diagrama de blocos do sistema é apresentado na Fig. 9.

Os dados de entrada são compostos por um conjunto de 10 ruídos de cavitação sintéticos (gerados pelo simulador fenomenológico), $x_n[n]$. Já para os dados de referência foi utilizado o ruído experimental do banco de dados da Espanha [21].

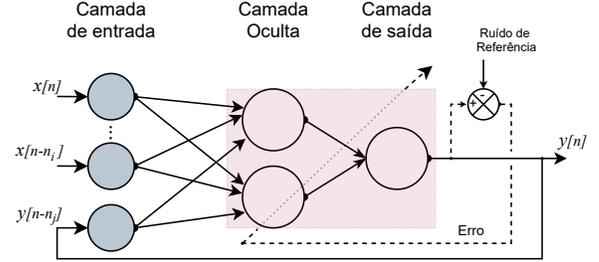


Figura 9: Diagrama de blocos da rede NARX

Para definição dos parâmetros da rede NARX foi adotado o procedimento empírico, onde, após uma série de simulações (variando a quantidade de neurônios na camada oculta e a quantidade de atrasos) foi possível encontrar a configuração que fornecesse o melhor desempenho da rede.

A Tabela I apresenta os parâmetros da rede neural adotada no trabalho. A rede implementada é composta por uma camada oculta, os pesos são inicializados de forma aleatória, conforme o método proposto por Nguyen e Widrow [22]. Como critério de parada, a rede foi configurada para interromper o treinamento caso, após seis iterações não consiga diminuir o erro de validação. Para o treinamento, houve uma variação do número de neurônios da camada oculta (1:10), com o intuito de encontrar a configuração que gerou o melhor resultado.

Para o processo de aprendizagem da rede, o conjunto de dados de entrada foi dividido da seguinte forma: 70% dos sinais foram direcionados para o treinamento da rede, 15% para validação e 15% para teste, com uma função de ativação sigmóide na camada oculta e uma função de ativação linear na saída.

Tabela I: Característica da Rede NARX

Números de Camadas	Número de neurônios	Número de Atrasos
1	1:10	2
Funções de Transferência	Camada Oculta	Camada de saída
	Sigmóide	Linear
Algoritmo de Treinamento	Scaled Conjugate Gradient	

IV. DADOS PARA VALIDAÇÃO

Para o desenvolvimento do trabalho foram utilizados sinais experimentais disponibilizados pela Universidade de Vigo (Espanha) [21]. As gravações foram realizadas no porto de Vigo (Espanha). O banco de dados é composto por 90 registros

que representam sons de 11 categorias de embarcações, por exemplo, barcos de pesca, lanchas e balsas de passageiros, também são disponibilizadas informações sobre aspectos técnicos das gravações e condições ambientais.

Para a aquisição dos sinais foi utilizado um conjunto de três hidrofones posicionados em diferentes profundidades, os hidrofones foram ancorados no fundo do porto e presos a uma boia submersa para garantir a verticalidade e uma boia de superfície para recuperação. A Fig. 10 ilustra o diagrama de aquisição dos sinais no porto de Vigo.

Para a obtenção dos sinais experimentais foram utilizados gravadores digitais acústicos com taxa de amostragem de 52.734 Hz. O banco de dados disponibilizado por [21] é útil para o desenvolvimento e teste de aplicativos baseados no processamento de sons de embarcações.

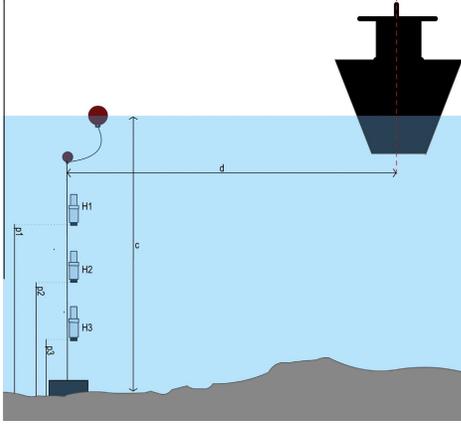


Figura 10: Sistema de aquisição de sinais acústicos submarinos do banco de dados *ShipEar*, adaptado de [21].

V. MÉTRICAS DE VALIDAÇÃO

Nessa seção, serão apresentadas as medidas de desempenho utilizadas para avaliar o simulador.

- (1) O desvio percentual médio de frequência (\bar{E}_{har}) é dado por (6) onde, F_q e Fx_q são, respectivamente, o valor de frequência do q -ésimo harmônico ($q = 1, 2, \dots, N_h$) do sinal gerado pelo simulador e o do sinal experimental de referência;

$$\bar{E}_{har} = \frac{1}{N_h} \sum_{q=1}^{N_h} \frac{|F_q - Fx_q|}{Fx_q} \cdot 100\% \quad (6)$$

- (2) O erro absoluto médio \bar{E}_{amp} entre as amplitudes dos N_h harmônicos do sinal do simulador (A_q) e os do sinal de referência (Ax_q) é dado por (7):

$$\bar{E}_{amp} = \frac{1}{N_h} \sum_{q=1}^{N_h} |A_q - Ax_q| [dB] \quad (7)$$

- (3) O erro entre os valores do nível médio de ruído de fundo do sinal do simulador fenomenológico (ANL_q) e o do sinal experimental (ANL_{xq}), é definido como Δ_{ANL} (8):

$$\Delta_{ANL} = |ANL_q - ANL_{xq}| [dB] \quad (8)$$

$$ANL_{q,xq} = \frac{1}{B} \sum_{k=1}^B A_{q,xq}[k] [dB] \quad (9)$$

em que:

$$A_{q,xq}[k] = \begin{cases} A_{q,xq}[k_q - \varepsilon], & \text{para } k_q - \varepsilon < k \leq k_q + \varepsilon \\ A_{q,xq}[k], & \text{caso contrário,} \end{cases}$$

$A_{q,xq}[k]$ é o espectro no k -ésimo índice de frequência discreta ($k = 1, 2, \dots, B$), B é o número de *bins* de frequência utilizado, $k_{q,xq} = F_{q,xq}/F_s$ é a frequência discreta dos N_h componentes harmônicos $F_{q,xq}$ e ε é o desvio de frequência em torno de cada $k_{q,xq}$, definindo a faixa em que os harmônicos são eliminados para o cálculo do valor $ANL_{q,xq}$. O valor de ε foi fixado empiricamente.

VI. RESULTADOS

Nesta seção, inicialmente serão apresentados os resultados do simulador fenomenológico, seguido dos resultados relacionados a implementação da rede neural NARX. Para validação do simulador fenomenológico e treinamento da rede neural, foram usados sinais experimentais disponibilizado pela Universidade de Vigo (Espanha) [21].

O sinal usado como referência é oriundo de uma embarcação usada para transporte de passageiros chamada Mar de Onza, ver Fig. 11, e, no momento da aquisição dos dados, a embarcação estava saindo do porto de Vigo, o ruído estado do mar estava entre os níveis 0 e 1 e não estava chovendo.



Figura 11: Embarcação para transporte de passageiros: Mar de Onza, adaptado de [23]

A. Simulador Fenomenológico

Inicialmente foi realizada uma análise DEMON do ruído experimental, ver Fig. 12, observa-se no demograma há presença de três harmônicos, o primeiro harmônico (847,7 RPM) está relacionado à rotação do eixo do hélice da embarcação, os harmônicos seguintes (1701 e 2548 RPM) indicam a quantidade de pás do hélice. As informações obtidas (velocidade de rotação e n.º de pás) serão utilizadas como referência no simulador fenomenológico.

Para geração do ruído fenomenológico, foram inseridas no módulo de cavitação as seguintes informações: velocidade de rotação do eixo do hélice (primeiro harmônico) e a quantidade de pás do hélice (número de harmônicos), o módulo gerador de ruído ambiente foi configurado para simular o ruído estado do mar nível 0, nível próximo do ruído ambiental na hora da aquisição do ruído experimental.

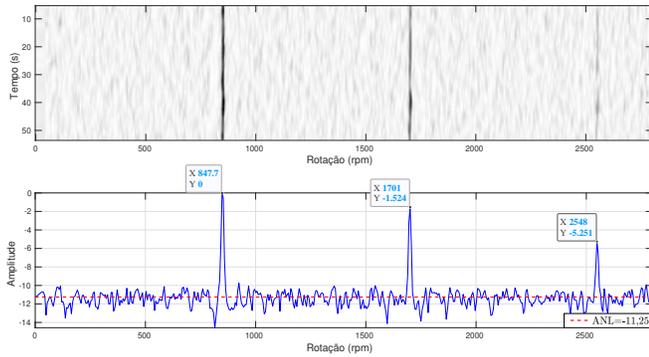


Figura 12: Análise DEMON do ruído experimental: embarcação Mar de Onza

O resultado é mostrado na Fig. 13. Comparando as Fig. 12 e 13, o \bar{E}_{har} entre os picos dos harmônicos do sinal experimental e fenomenológico foi de 1.58% e o \bar{E}_{amp} foi de 2,480 dB, respectivamente. Para o erro médio entre os ruídos de fundo foi de 1,8 dB.

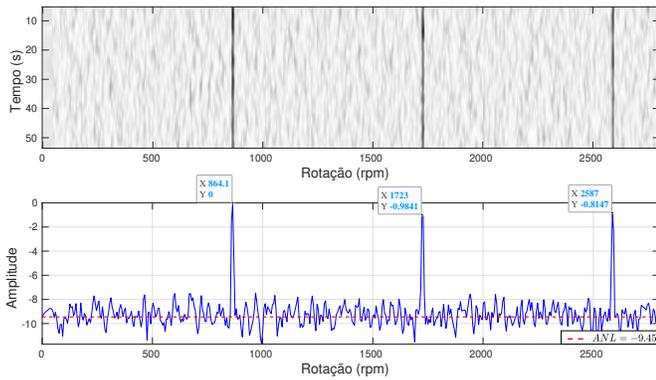


Figura 13: Análise DEMON do ruído fenomenológico

B. Rede NARX

A partir dos resultados apresentados na seção VI-A, percebe-se que o simulador fenomenológico consegue gerar um ruído de cavitação com comportamento espectral próximo do ruído experimental. No entanto, ele não consegue incorporar informações não-lineares ao ruído fenomenológico, como, por exemplo, a diferença de intensidade de cavitação de cada pá (intensidade dos harmônicos). Visando aproximar o simulador fenomenológico do ruído experimental, foi implementado uma rede neural NARX após o simulador fenomenológico.

Utilizando os ruídos do simulador fenomenológico como dados de entrada para a rede e o ruído experimental (embarcação MAR de ONZA) como sinal de referência, foi realizado o treinamento da rede. Para encontrar a melhor configuração da rede neural, foi feita uma variação do número de neurônios da camada oculta (entre 1 e 10 neurônios).

O treinamento que forneceu o melhor resultado foi a rede com configuração com 3 neurônios. Para configurações superiores não foi detectada melhorias no ruído, no entanto, houve um aumento no tempo de treino e uma maior exigência

de processamento do computador. A Fig. 14 apresenta o decaimento do erro, o treino foi interrompido na interação 257.

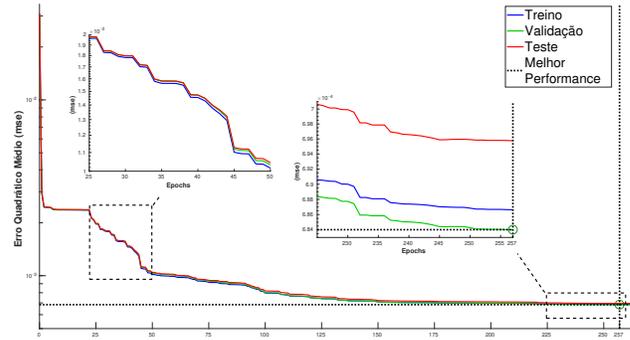


Figura 14: Gráfico do treino da rede NARX

A Fig. 15 apresenta a análise DEMON do ruído gerado no treinamento da rede contendo 3 neurônios. Observa-se que a rede NARX conseguiu aproximar o ruído fenomenológico do experimental, a velocidade de rotação do eixo do hélice e os valores dos harmônicos estão correspondendo ao do ruído experimental, no entanto, a intensidade dos harmônicos, apesar de se aproximarem, não estão iguais ao ruído experimental, o \bar{E}_{amp} foi de 0,01 dB. O ruído médio de fundo, ANL entre os dois ruídos está bem próximo, $\Delta_{ANL} = 0,06$.

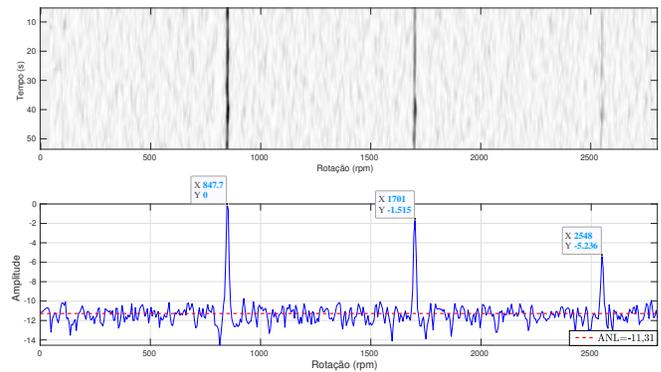


Figura 15: Ruído gerado no treinamento da rede NARX: Embarcação Mar de Onza

Após o treinamento, foi realizada uma avaliação das redes já treinadas (1 a 10 neurônios) utilizando um novo conjunto de dados. O intuito é avaliar o desempenho de cada rede, pois, após o treinamento, não haverá mais ajustes dos pesos, também não será fornecido um ruído de referência. As redes que forneceram melhor resultados no teste foram as redes com 2 e 9 neurônios, Fig. 16 e Fig. 17, respectivamente.

Comparando os resultados do teste das redes, ver Tabela II, observa-se que tanto a rede com 2 neurônios quanto a rede com 9 conseguiram melhorar o ruído gerado pelo simulador fenomenológico. A rede com 2 neurônios conseguiu um melhor desempenho da performance \bar{E}_{amp} , enquanto a rede com 9 neurônios gerou melhores resultado no Δ_{ANL} . Com relação

a frequência dos harmônicos, nenhuma das redes apresentou melhoras.

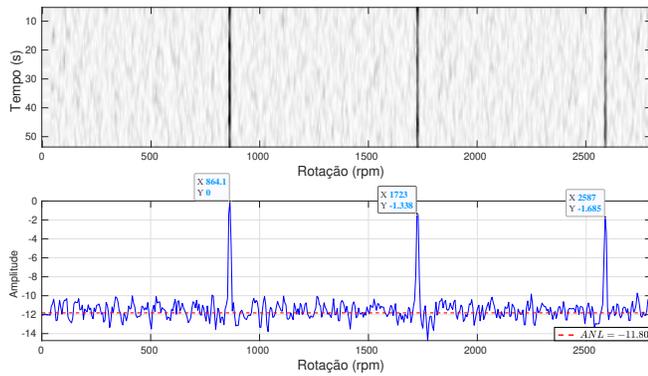


Figura 16: Sinal gerado pela rede com 2 neurônios: Embarcação Mar de Onza

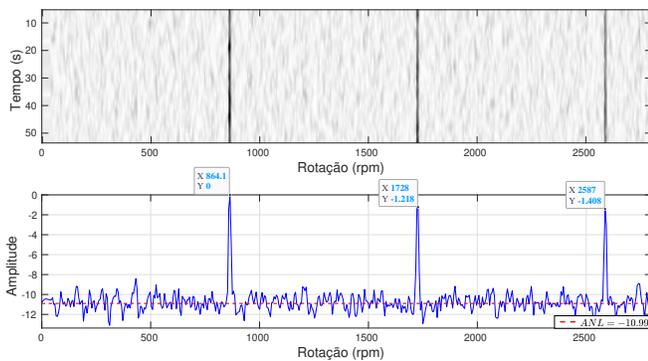


Figura 17: Sinal gerado pela rede com 9 neurônios: Embarcação Mar de Onza

Também foi feita análise do simulador de ruídos acústicos no domínio do tempo. Na Fig. 18, observou-se que a rede NARX consegue gerar um sinal mais próximo do sinal experimental do que o simulador fenomenológico.

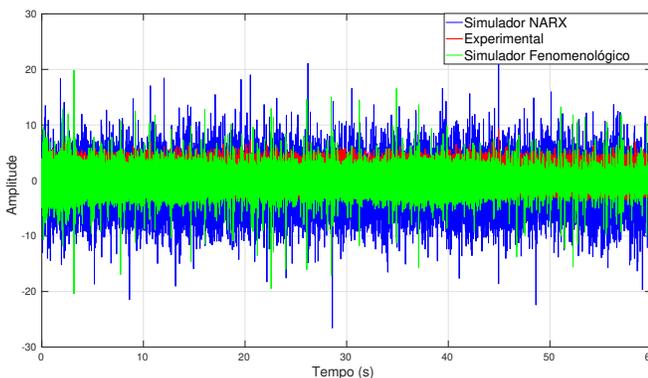


Figura 18: Sinais gerados pelo simulador no domínio do tempo da embarcação MAR de Onza

Com o intuito de verificar o desempenho da rede NARX para outros sinais experimentais, foi realizado o treinamento e teste da rede usando o sinal de outra embarcação, o sinal experimental pertence a um navio usado para o transporte de

cargas (Eimskip Reefer). A Fig. 19 apresenta demograma do Eimskip Reefer, observa-se no demograma a presença de cinco harmônicos, o que indica a presença de um hélice com 5 pás e velocidade de rotação em 486,7 RPM.

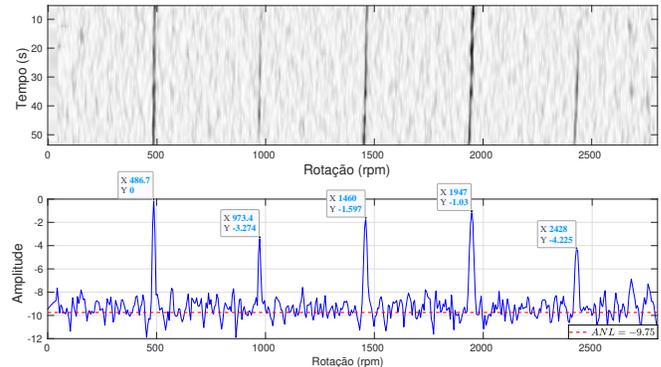


Figura 19: Análise DEMON da Eimskip Reefer

As Fig. 20 e 21 apresentam, respectivamente, a análise DEMON para os sinais gerados pelo simulador fenomenológico e rede NARX. A rede que gerou melhor resultado foi a rede com 9 neurônios na camada oculta. A Tabela II apresenta a comparação entre as análises de desempenho, nota-se que a rede NARX forneceu bons resultados para o ruído de fundo, $\Delta_{ANL} = 0,23$, no entanto, a rede não conseguiu melhorar as frequências dos harmônicos.

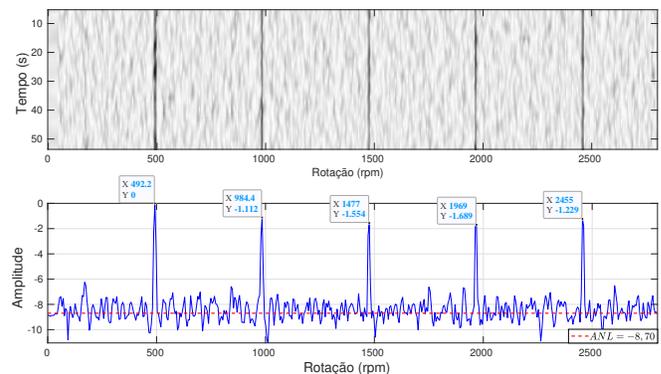


Figura 20: Ruído fenomenológico: Embarcação Eimskip Reefer

VII. CONCLUSÕES

Este trabalho teve como objetivo desenvolver um sistema capaz de sintetizar ruídos acústicos submarinos. A princípio, utilizando o simulador fenomenológico, foi gerado um ruído a partir de informações de uma embarcação de transporte de passageiros. Os resultados obtidos pela análise DEMON mostraram que o simulador fenomenológico pode simular um ruído de cavitação com comportamento espectral próximo das especificações fornecidas ao simulador.

Em seguida, com o intuito de aproximar o ruído fenomenológico do ruído experimental, foi incorporado ao simulador uma rede neural NARX. A rede apresentou resultados satisfatórios ao tentar aproximar o ruído fenomenológico do expe-

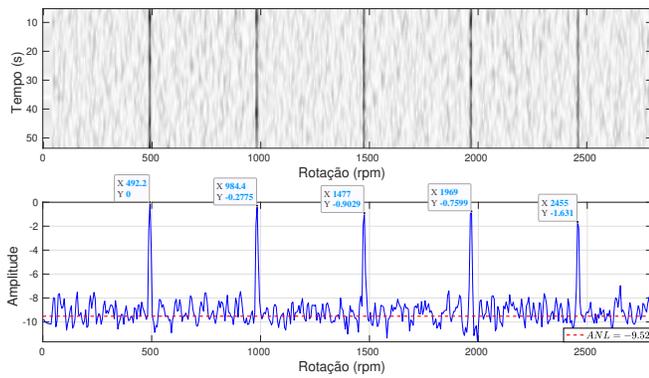


Figura 21: Sinal gerado pela rede com 9 neurônios: Eimskip Reefer

Tabela II: Comparação dos índices de desempenho entre o sinal experimental e o simulador.

Embarcação Mar de Onza	\bar{E}_{har} (%)	\bar{E}_{amp} (dB)	Δ_{ANL} (dB)
Simulador Fenomenológico	1,58	2,48	1,8
Treinamento da Rede	0	0,01	0,06
Teste da rede c/ 2 neurônios	1,58	1,87	0,55
Teste da rede c/ 9 neurônios	1,68	2,07	0,26
Embarcação Eimskip Reefer	\bar{E}_{har} (%)	\bar{E}_{amp} (dB)	Δ_{ANL} (dB)
Simulador Fenomenológico	1,13	1,46	1,05
Teste da rede c/ 9 neurônios	1,13	1,63	0,23

imental. Analisando os resultados vê-se que a rede NARX tem bom desempenho ao tentar aproximar o ruído banda larga, já para a banda estreita a rede encontrou dificuldades para melhorar o ruído fenomenológico. A rede também gerou bons resultados para o ruído no domínio do tempo. Uma das dificuldades encontradas ao trabalhar com a rede neural para aprimorar o simulador, foi a necessidade de maior processamento de dados. À medida que incrementamos a configuração da rede com o intuito de obter melhores resultados, maior foi a exigência de processamento.

Para trabalhos futuros, implementações de diferentes arquiteturas de aprendizado de máquinas, como, por exemplo, modelo LSTM (*Long short-term memory*) objetivando melhorar o simulador de ruído acústico, tanto no domínio do tempo quanto da frequência, serão desenvolvidas.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Os autores gostariam de agradecer também à FAPESB, FAPERJ e CNPq pelo apoio financeiro, e à Marinha do Brasil, por disponibilizar os dados experimentais e à Sonitum - AtlantTIC (Universidade de Vigo) pelo acesso ao conjunto de dados experimentais.

REFERÊNCIAS

- [1] P. C. Etter, *Underwater acoustic modeling and simulation*. CRC press, 2018.
- [2] F. Francisco and J. Sundberg, "Detection of visual signatures of marine mammals and fish within marine renewable energy farms using multibeam imaging sonar," *Journal of Marine Science and Engineering*, vol. 7, p. 22, Jan 2019.
- [3] G. Yu, D. Zhao, and S. Piao, "Target detection method using multipath information in an underwater waveguide environment," *IET Radar, Sonar & Navigation*, vol. 14, no. 2, pp. 226–232, 2020.
- [4] B. Chen, Y. Yang, J. Zhou, Y. Zhuang, and M. McFarland, "Damage detection of underwater foundation of a chinese ancient stone arch bridge via sonar-based techniques," *Measurement*, vol. 169, p. 108283, 07 2020.
- [5] R. P. Hodges, *Underwater Acoustics Analysis, Design and Performance of SONAR*. Reino Unido: John Wiley and Sons, Ltd, 2010.
- [6] L. Bjørnø, T. Neighbors, and D. Bradley, *Applied Underwater Acoustics: Leif Bjørnø*, 02 2017.
- [7] M. K. Pine, K. Nikolich, B. Martin, C. Morris, and F. Juanes, "Assessing auditory masking for management of underwater anthropogenic noise," *The Journal of the Acoustical Society of America*, vol. 147, no. 5, pp. 3408–3417, May 2020.
- [8] G. Guillermo, D. Ponce, J. Telles, and C. Carpio, "An algorithm to obtain boat engine rpm from passive sonar signals based on demon processing and wavelets packets transform," *Journal of Electrical Engineering & Technology*, vol. 14, 08 2019.
- [9] N. N. de Moura, J. M. de Seixas, and R. Ramos, "Passive sonar signal detection and classification based on independent component analysis," *Sonar Systems, InTech*, pp. 93–103, 2011.
- [10] Y. Wang, H. Li, and W. Dai, "Application of duffing oscillator in ship propeller blade number recognition," 2016, pp. 1–5.
- [11] J. B. O. S. Filho, "Classificação neural de sinais de sonar passivo," Ph.D. dissertation, COPPE/UFRJ, 2007.
- [12] F. L. Santos, "Auxílio à classificação sonar passiva por tons característicos," Ph.D. dissertation, Universidade Federal do Rio de Janeiro - COPPE-PEO, 2005.
- [13] N. Fisheries, "Ocean noise and soundscape projects," Mar 2021. [Online]. Available: <https://www.fisheries.noaa.gov/new-england-mid-atlantic-ocean-noise-and-soundscape-projects>
- [14] D. L. Bradley and R. Stern, *Underwater sound and the marine mammal acoustic environment: A guide to fundamental principles*. Bethesda, MD : Marine Mammal Commission,, 2008.
- [15] R. M. de Amorim, "Avaliação da influência do ruído ambiente em sistema sonar passivo utilizando análise de componentes independentes," Master's thesis, Universidade Federal da Bahia - PPGEE/UFBA, Bahia, 2016.
- [16] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- [17] Z. Yi, *Convergence analysis of recurrent neural networks*. Springer Science & Business Media, 2013, vol. 13.
- [18] Z. Boussaada, O. Curea, A. Remaci, H. Camblong, and N. M. Bellaaj, "A nonlinear autoregressive exogenous (narx) neural network model for the prediction of the daily direct solar radiation," *Energies*, vol. 11, no. 3, p. 620, 2018.
- [19] S. Minfen, L. Sun, and F. H. Y. Chan, "Generation of noise sequences with desired non-gaussian distribution, and covariance," *2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering. TENCOM '02. Proceedings.*, vol. 2, pp. 1105–1108, 2002.
- [20] Z. Zhiu and Z. Yong-sheng, "Research on the underwater vehicle radiated noise model and the linear spectrum extraction method," *2016 13th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, pp. 819–823, 2016.
- [21] D. Santos-Domínguez, S. Torres-Guijarro, A. Cardenal-López, and A. Pena-Gimenez, "Shipsear: An underwater vessel noise database," *Applied Acoustics*, vol. 113, pp. 64–69, 2016.
- [22] D. Nguyen and B. Widrow, "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights," *1990 IJCNN International Joint Conference on Neural Networks*, pp. 21–26, 1990.
- [23] "Vessel mar onza, vessel details and voyage information - registered in spain." [Online]. Available: https://www.marinetraffic.com/en/ais/details/ships/shipid:164118/mmsi:224081370/imo:0/vessel:MAR_ONZA