

Simulador de Ruído Acústico Submarino da Maquinaria de Navios para Aplicações em Sonar Passivo e Utilizando uma Rede Neural NARX

Anderson Damacena Santos, Elio P. Sarno Filho,
Eduardo F. de Simas Filho e Antônio C. L. Fernandes Jr.
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal da Bahia
Salvador, Brasil

(anderson.damacena,elio.pithon,eduardo.simas,antonio.lopes)@ufba.br

José M. de Seixas
Laboratorio de Processamento de Sinais
Coppe/Poli - Universidade Federal do Rio de Janeiro
Rio de Janeiro, Brasil
seixas@lps.ufrj.br

Resumo—Os sistemas de sonar passivo possuem aplicações abrangentes tanto em cenários civis quanto militares, desempenhando funções importantes, como a vigilância do ambiente submarino e a detecção de animais e embarcações. Devido à complexidade de obter dados acústicos submarinos, surge a necessidade de criar bancos de dados acústicos. No entanto, essa tarefa não é simples, pois requer a aquisição de equipamentos específicos e envolve custos consideráveis para instalação e manutenção. Tendo em vista a falta de dados relacionados aos ruídos acústicos submarinos, o objetivo deste artigo é apresentar um simulador que produz a combinação de ruído de máquinas de embarcações com ruído ambiente a partir da descrição dos fenômenos físicos, utilizando modelos matemáticos baseado em conceitos estatísticos e técnicas de aprendizado de máquina. Esse simulador visa preencher essa lacuna e permitir estudos e pesquisas nessa área.

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

I. INTRODUÇÃO

Nos últimos anos, houve um considerável aumento no uso de sistemas sonar (*Sound navigation and ranging*) em aplicações submarinas [1]. Sistemas sonar submarinos são classificados em duas categorias: ativos e passivos [2]. Os sonares ativos possuem a característica de emitir um pulso sonoro que, ao refletir em um obstáculo, retorna à fonte original, permitindo a detecção, localização e classificação do alvo. Esses sonares ativos são comumente utilizados em aplicações civis, por exemplo, auxílio na localização de cardumes, mapeamento do fundo do mar e comunicação subaquática [3].

Por outro lado, o sonar passivo é utilizado para a detecção e monitoramento de alvos, sendo sua principal característica a não emissão de sinal, como apresentado por [4]. Para detectar o alvo de interesse, o sonar passivo se baseia no comportamento do alvo como uma fonte de sinais acústicos, os quais se propagam pelo meio aquático até alcançar os receptores do sonar. O sonar passivo desempenha um papel fundamental em operações de submarinos militares.

O processamento para extração de informações desempenha um papel crucial em um sistema sonar. Geralmente realizado

de maneira automática, os módulos de processamento digital auxiliam o operador sonar a tomar decisões relacionadas à caracterização da embarcação [5]. Uma das técnicas de processamento de sinais utilizadas no contexto do sonar passivo é a análise LOFAR (*Low frequency analysis and recording*) [6], que consiste em um analisador espectral de banda larga que opera sobre o ruído da maquinaria da embarcação. Através dessa análise do sinal irradiado pelas embarcações, é possível apresentar de forma visual o comportamento espectral do ruído da maquinaria no domínio da frequência e do tempo.

No contexto do sonar passivo, um dos desafios é a obtenção de dados experimentais. A escassez de informações disponíveis sobre ruídos acústicos submarinos muitas vezes requer que os pesquisadores criem seus próprios conjuntos de dados, o que implica em investimentos significativos em recursos humanos, equipamentos e instalações apropriadas. Isto pode ser observado em [7], banco de dados criado a partir de gravações de embarcações obtidas no porto de Vigo, na Espanha. Além disso, garantir a condição ambiental ideal durante a coleta dos dados é uma tarefa desafiadora.

Em [8], propõe-se gerar um ruído acústico submarino baseado em uma rede adversária generativa (*Generative adversarial networks* - GAN), já em [9] é proposto um simulador de sinal de retroespalhamento de alvos submarinos voltado para o treinamento de tecnologia para detecção de sonar ativo. Em [10], utiliza-se a capacidade de aprendizado da rede neural recorrente (RNN) e da rede neural convolucional (CNN) para projetar um modelo de reconhecimento de modulação para sinais acústicos subaquáticos.

Neste contexto, o presente artigo propõe desenvolver um modelo baseado em conceitos estatísticos e de aprendizado de máquinas, deste modo, criar um simulador capaz de gerar ruídos emitidos por embarcações (especificamente, ruído de maquinaria) em diferentes cenários de operação. Essa abordagem oferecerá à comunidade científica a oportunidade de obter dados sintéticos para abordar desafios em diversas situações, incluindo a validação de técnicas de processamento de sinais de sonar passivo. O modelo proposto é composto por um

simulador fenomenológico e uma rede neural.

É importante ressaltar que este trabalho é uma continuação direta de um trabalho apresentado anteriormente no congresso CBIC 2021 [11], o artigo, escrito pelo mesmo autor, tinha como foco a geração do ruído de cavitação. Esse artigo utiliza informações previamente apresentadas em [11], além disso, esse trabalho incorpora novos elementos e atualizações (ruído de maquinaria), ampliando o escopo do estudo e enriquecendo a compreensão do tema em discussão. Ao expandir e aprimorar as descobertas anteriores, o artigo busca contribuir de forma significativa para o avanço do conhecimento científico nessa área específica de pesquisa.

II. FUNDAMENTAÇÃO TEÓRICA

A. Ruído de Máquinas

O ruído de maquinaria é produzido a partir das vibrações das máquinas. Elas se propagam pelo casco do navio e acabam sendo irradiadas para o meio submarino, conforme mostrado na Fig. 1. O ruído irradiado pelas maquinarias tem contribuições significativas no meio submarino, e uma que se destaca é o ruído dos motores a diesel [12], [13].

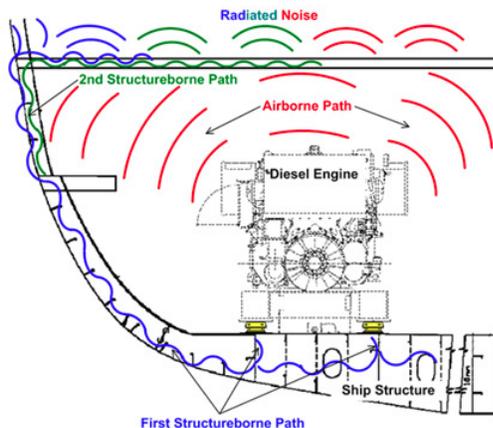


Figura 1: Ilustração das fontes de ruído provenientes da Maquinaria: motor a diesel, adaptado de [14]

Um dos motivos que levam o motor a diesel a contribuir para com o ruído irradiado é que ele é composto por várias partes móveis [15], como, por exemplo, os pistões. Quando o motor está em funcionamento os pistões, ao se movimentarem, se chocam com as paredes dos cilindros [16]. Quando em funcionamento, as partes móveis do motor se movem a intervalos específicos, gerando um ruído característico composto por tons espectrais.

B. Ruído Ambiente

As fontes naturais presentes no ambiente acústico submarino contribuem para a ocorrência do ruído ambiente. Duas das principais fontes de ruído acústico ambiente são a chuva e o estado do mar [13].

O ruído da chuva é produzido quando as gotas de chuva atingem a superfície da água, resultando em oscilações na superfície e no ar abaixo dela [13]. Esse ruído é classificado

em quatro níveis, cada um correspondendo a uma taxa de precipitação específica. A Fig. 2a apresenta o espectro de frequência do ruído da chuva para diferentes níveis.

Por sua vez, o ruído estado do mar é uma combinação de diferentes fontes de ruído, como a quebra das ondas na superfície do oceano [13]. O estado do mar é categorizado em sete níveis, e a Fig. 2b ilustra o espectro de frequência do ruído estado do mar para diferentes intensidades.

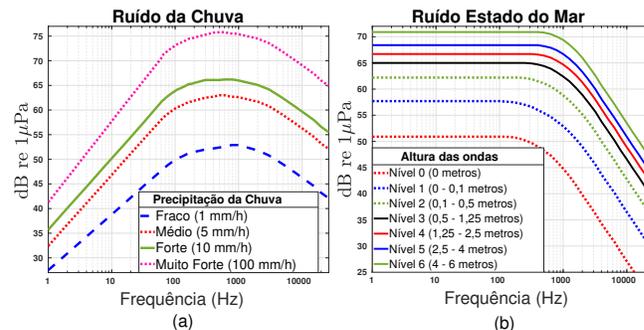


Figura 2: Ruído Ambiente: (a) chuva (b) estado do mar.

C. Análise LOFAR

A análise LOFAR (*Low frequency analysis and recording*) é uma técnica utilizada para analisar sinais em sistemas sonar. Essa técnica é voltada para a detecção do ruído relacionado à maquinaria da embarcação. Realizada em toda a banda de frequência do sinal, o LOFAR busca obter informações referentes ao ruído irradiado proveniente das vibrações das máquinas do navio [17].

A Fig. 3 mostra o diagrama de blocos da análise LOFAR. Após a seleção do áudio a ser analisado, o mesmo é janelado por uma janela de Hanning. Em seguida, é aplicada a transformada de Fourier com o objetivo de obter uma representação do ruído no domínio da frequência, e na sequência, é realizada a normalização do sinal. A normalização permite uma estimativa mais fácil do ruído de fundo. Com uma evidência maior dos picos de frequência de baixa intensidade (ruído de fundo), é possível normalizar as amplitudes do sinal e atenuar o ruído de fundo.

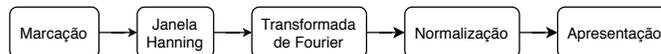


Figura 3: Diagrama de blocos da análise LOFAR.

A Fig. 4 apresenta a análise LOFAR de uma embarcação. Os tons espectrais encontrados na figura estão relacionados ao ruído irradiado pela maquinaria da embarcação, sendo esses harmônicos referentes às partes móveis do motor a diesel.

D. Rede Neural NARX

As redes neurais artificiais (RNAs) são modelos computacionais inspiradas nos processos de aprendizagem dos neurônios do cérebro humano [18]. Ao longo dos anos, as RNAs têm sido amplamente estudadas com o objetivo de reproduzir o desempenho do mecanismo de aprendizagem humano. Entre

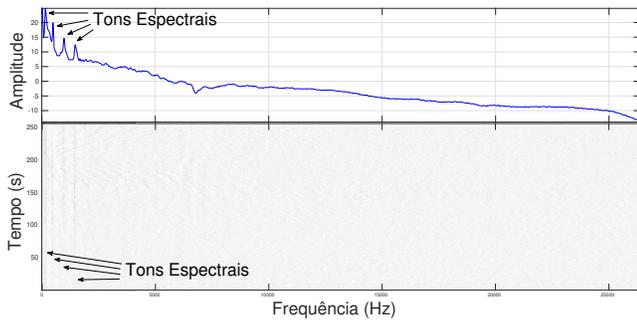


Figura 4: Exemplo de Análise LOFAR.

as diferentes arquiteturas, destaca-se a rede neural recorrente (*recurrent neural network* - RNN).

As RNNs se diferenciam de outras arquiteturas de redes neurais pelo fato de possuírem uma ou mais conexões de retroalimentação nas camadas da rede [19]. Isso significa que as RNNs recebem entradas de duas fontes, conforme ilustrado na Fig. 5. Devido à consideração do tempo e da seqüência dos sinais, a arquitetura recorrente se mostra adequada para lidar com processos estocásticos tanto em sistemas de tempo contínuo quanto em tempo discreto [20].

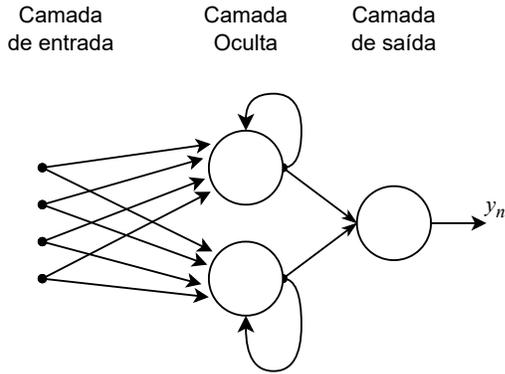


Figura 5: Rede Neural Recorrente.

A arquitetura NARX (*Nonlinear autoregressive with exogenous inputs*) é uma variante de rede recorrente amplamente utilizada na modelagem de sistemas não-lineares [21]. Essa arquitetura, baseada em um *perceptron* multicamadas, permite múltiplas entradas e realimentação da saída para a entrada, como ilustrado na Fig. 6.

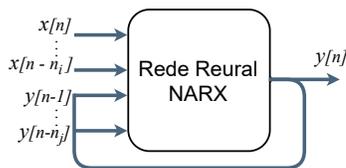


Figura 6: Rede recorrente NARX.

III. SIMULADOR PROPOSTO

Para a modelagem do ruído, uma vez que o ruído do motor diesel é composto por tons espectrais, foi implementado um somatório de cossenos, conforme Equação (1), onde f é a frequência de vibração das partes do motor, A_m é a amplitude de cada frequência e n é o número de harmônicos de cada componente.

$$M(t) = \sum_{n=1}^N A_m \cos(2\pi nft). \quad (1)$$

A frequência irradiada por cada componente é apresentada na Tabela I; no entanto, não é possível determinar com precisão a frequência de vibração de cada peça devido ao fato de as peças do motor trabalharem em intervalos parecidos [22].

Tabela I: Frequências de vibração de um motor a diesel

Origem da Vibrações	Frequência de vibração
Disparos dos cilindros (Cylinder firing rate)	$f_{cfr} = \frac{kn_s}{2 \cdot 60}$
Eixo de manivelas (Crankshaft)	$f_c = \frac{kn_s}{60}$
Válvulas de motor (Engine valves)	$f_v = \frac{kz_p n_s z_z}{m60}$
Impactos dos pistões (Piston slap)	$f_{ps} = \frac{kz_p n_s}{60}$
Anéis dos pistões (Piston rings)	$f_{pr} = \frac{kbz_p n_s}{60}$

onde:

- k : número do harmônico
- n_s : velocidade rotacional da máquina (rpm);
- z_p : número de pistões da máquina;
- z_z : número de válvulas em um pistão;
- b : número de anéis em um pistão;
- m : indica se o motor é de dois ou quatro ciclos de tempo;

Para a modelagem dos ruídos ambiente da chuva e do estado do mar, assumimos uma distribuição Gaussiana para ambos [13], adotou-se o modelo proposto na Fig. 7, onde $x[n]$ representa um ruído gaussiano branco, $h[n]$ é a resposta ao impulso do sistema linear e invariante no tempo (LIT), e $y[n]$ é um ruído gaussiano colorido. O objetivo é obter um sinal que tenha uma densidade espectral de potência (*power spectral density* - PSD) similar ao comportamento espectral dos ruídos ambiente apresentados na Fig. 2.

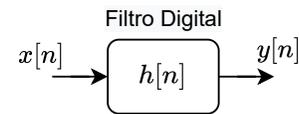


Figura 7: Diagrama de blocos para o sistema proposto.

É mostrado na Equação (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 ao quadrado da resposta em frequência, $|H(e^{j\omega})|^2$. Essa abordagem se baseia na propriedade de que uma transformação linear de um processo gaussiano resultará em uma saída Gaussiana [23].

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

Com base na Equação (2), é possível determinar a magnitude da resposta em frequência do filtro $|H(e^{j\omega})|$ a partir da PSD de saída conhecida, $S_y(e^{j\omega})$. Considerando que a PSD de entrada, $S_x(e^{j\omega})$, é constante em toda a banda de frequência ω de interesse devido ao ruído branco $x[n]$ ser de banda limitada, essa relação pode ser obtida utilizando a Equação (3). Para estimar $|H(e^{j\omega})|$, foram utilizados os pares $|S_y(e^{j\omega_i})|$ e ω_i obtidos de [13].

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

Após a finalização da etapa de modelagem do simulador fenomenológico, deu-se início à implementação da rede NARX, como mostrado na Fig. 8. O ruído sintético gerado pelo simulador fenomenológico (ruído de maquinaria) será utilizado como entrada para a rede. Quanto aos dados de referência, optou-se por utilizar o ruído experimental presente no banco de dados da Espanha [7].

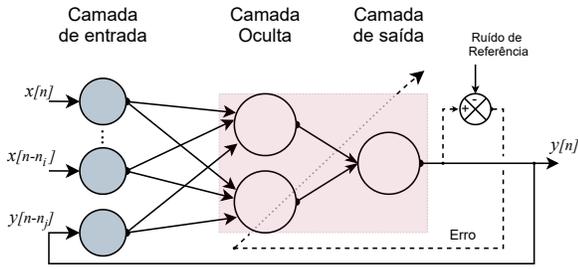


Figura 8: Diagrama de blocos da rede NARX

A tabela a seguir (Tabela II) apresenta os parâmetros utilizados na configuração da rede neural adotada neste estudo. A rede implementada consiste em uma camada oculta, na qual os pesos são inicializados de forma aleatória, seguindo o método proposto por Nguyen e Widrow [24]. Foi estabelecido como critério de parada que o treinamento será interrompido caso o erro de validação não diminua após seis iterações consecutivas.

Durante o processo de treinamento, foram exploradas diferentes configurações com variações independentes tanto no número de neurônios da camada oculta quanto no número de atrasos. O número de neurônios variou de 1 a 5, enquanto os atrasos foram aplicados tanto na camada de entrada da rede quanto na realimentação (da saída para a entrada). Essas modificações foram realizadas em incrementos de 5 unidades, abrangendo um intervalo de valores de 1 a 50.

No processo de aprendizagem da rede neural, os dados de entrada foram divididos em três conjuntos: 70% para o treinamento da rede, 15% para a validação e 15% para o teste. A camada oculta utiliza a função de ativação sigmoide, enquanto a camada de saída emprega uma função de ativação linear.

Tabela II: Característica da Rede NARX

Número de camadas intermediárias.	Número de neurônios na camada intermediária.	Número de Atrasos
2	1:5:50	1:5:50
Funções de Transferência	Camada Oculta (intermediária)	Camada de saída
	Sigmoide	Linear
Algoritmo de Treinamento	Scaled Conjugate Gradient	

IV. DADOS PARA VALIDAÇÃO

Após a simulação dos sinais, foi feita uma comparação com dados experimentais obtidos de um banco de dados fornecido pela Universidade de Vigo, na Espanha, denominado *Ship-sEar* [7]. Esse banco de dados contém gravações de 11 tipos de embarcações, incluindo sons reais de maquinaria, variação de velocidade e ruído ambiente. Esses dados experimentais foram utilizados para validar os resultados obtidos.

No processo de captação dos sinais, utilizou-se um conjunto de três hidrofones posicionados em diferentes profundidades. Esses hidrofones foram fixados no fundo do porto e conectados a uma boia submersa. A Fig. 9 ilustra o diagrama de aquisição dos sinais no porto de Vigo. Para a obtenção dos dados experimentais, foram empregados gravadores digitais acústicos com uma taxa de amostragem de 52.734 Hz.

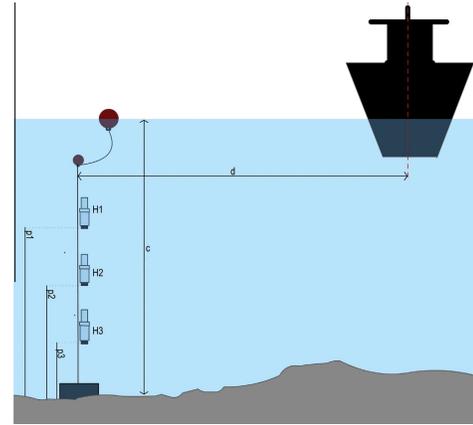


Figura 9: Sistema de aquisição de sinais acústicos submarinos do banco de dados *ShipEar*, adaptado de [7].

V. MÉDIDAS 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 calculado usando a Equação (4), em que Fq e Fxq representam, respectivamente, o valor de frequência do q -ésimo harmônico ($q = 1, 2, \dots, N_h$) do sinal gerado pelo simulador e do sinal experimental de referência;

$$\bar{E}_{har} = \frac{1}{N_h} \sum_{q=1}^{N_h} \frac{|Fq - Fxq|}{Fxq} \cdot 100\% \quad (4)$$

- (2) O erro absoluto médio \bar{E}_{amp} entre as amplitudes dos N_h harmônicos do sinal do simulador (A_q) e as do sinal de referência (Ax_q) é calculado usando a Equação (5):

$$\bar{E}_{amp} = \frac{1}{N_h} \sum_{q=1}^{N_h} |A_q - Ax_q| [dB] \quad (5)$$

- (3) Distância de Wasserstein: é uma medida da distância entre duas distribuições. Ela quantifica o custo mínimo necessário para transformar uma distribuição na outra.

$$d(F_q, Fx_q) = \left(\frac{1}{n} \sum_{q=1}^n \|F_q - Fx_q\|^p \right)^{\frac{1}{p}} \quad (6)$$

onde F_q e Fx_q são as representações das distribuições no domínio da frequência, e $\|\cdot\|$ indica a norma utilizada para medir a distância entre as representações. Aqui, p é a distância entre duas medidas de probabilidade.

VI. RESULTADOS

Nesta seção, serão apresentados os resultados referentes ao simulador de ruído de maquinaria de navio. Inicialmente, serão apresentados os resultados referentes à geração do ruído fenomenológico, seguidos da implementação da rede NARX. O sinal usado como referência para o simulador é proveniente de um navio de cruzeiro chamado MSC Opera, conforme mostrado na Fig. 10.



Figura 10: Navio de Cruzeiro: MSC Opera, adaptado de [25]

A. Simulador Fenomenológico

Para a geração do ruído fenomenológico, foi utilizado como referência o sinal experimental do navio MSC Opera. A Fig. 11 apresenta a análise LOFAR do sinal experimental. No lofargrama, observa-se a presença de tons espectrais, sendo que esses harmônicos estão relacionados ao ruído de maquinaria da embarcação. O primeiro harmônico (154,5 Hz) está associado à velocidade rotacional do motor a diesel.

Após analisar o sinal experimental e obter informações sobre os tons espectrais, procedeu-se à simulação de um ruído de maquinaria com base nos harmônicos identificados na Fig. 11, levando em consideração a velocidade de rotação

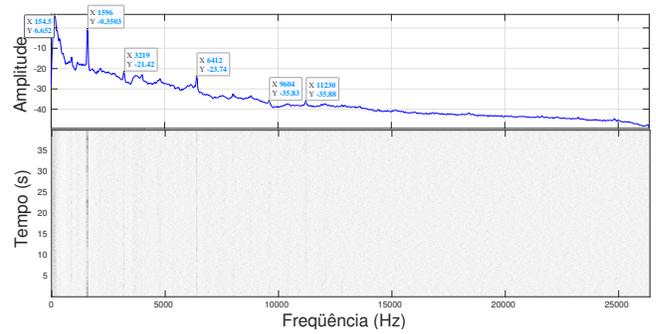


Figura 11: Análise LOFAR do sinal experimental.

e o número de harmônicos. O resultado dessa simulação é apresentado na Fig. 12.

Ao comparar as Fig. 11 e 12, é evidente que o simulador fenomenológico é capaz de gerar um sinal que apresenta tons espectrais com características tonais semelhantes às do sinal experimental. Observa-se na Fig. 12 a presença de um harmônico em 77 Hz no sinal fenomenológico. Esse harmônico é gerado a partir da frequência de disparo do cilindro (f_{cfr}), o que introduz um harmônico antes do harmônico resultante da rotação do motor.

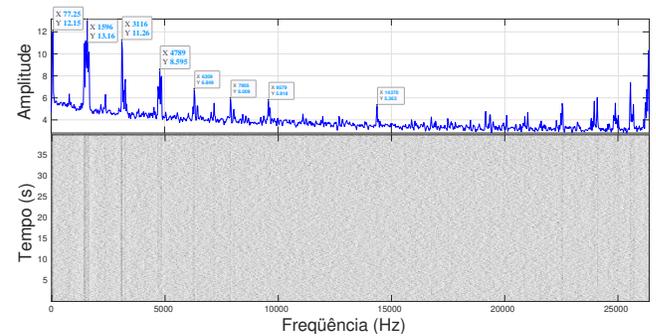


Figura 12: Análise LOFAR do sinal fenomenológico.

A Fig. 13 mostra a comparação entre o sinal experimental e o sinal fenomenológico. Na Fig. 13a, observa-se que a partir de 150 Hz, ocorre um decaimento em todo o espectro de frequência. Isso se deve ao fato de o sinal experimental ter passado por um tratamento, como a aplicação de um filtro passa-alta com uma frequência de corte de 100 Hz, para minimizar o ruído ambiente. No entanto, esse tratamento não foi implementado no simulador fenomenológico. O objetivo é verificar se a rede NARX é capaz de incorporar as características não-lineares presentes nos sinais experimentais.

A comparação dos sinais na faixa de frequência de 1 a 3000 Hz é apresentada na Fig. 13b. Ao examinar o sinal fenomenológico, é claramente perceptível a presença do harmônico de 77 Hz, que é gerado pela taxa de disparo. No entanto, no sinal experimental, não há uma distinção evidente da informação relacionada à frequência de 77 Hz. Isso pode ser atribuído ao fato de que o espectro está crescendo entre 1 e 154 Hz, resultando na falta de nitidez do tom spectral.

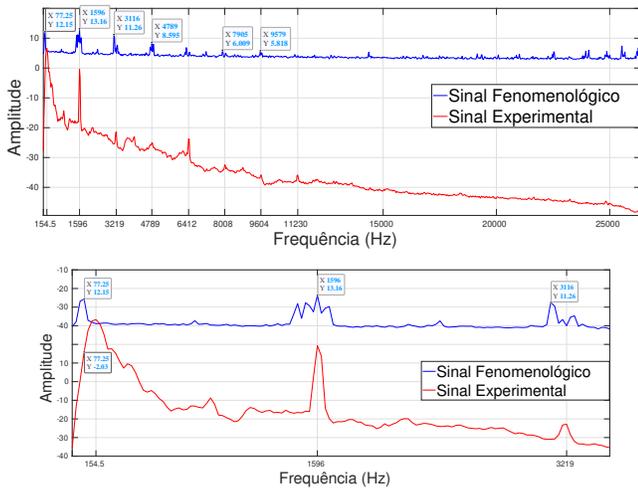


Figura 13: Comparação do sinal experimental e do sinal fenomenológico: (a) banda de frequência - 1 a 26.367 Hz (b) banda de frequência - 1 a 3.500 Hz.

B. Rede NARX

Nesta seção, serão apresentados os resultados da implementação da rede NARX. Inicialmente, procedeu-se ao treinamento da rede, utilizando o ruído gerado pelo simulador fenomenológico como entrada e o sinal experimental como referência. Foram feitas variações no número de neurônios e na quantidade de atrasos tanto na camada de entrada quanto na realimentação.

A configuração de treinamento que proporcionou o melhor resultado foi a rede com 4 neurônios, um atraso de 30 amostras na camada de entrada e 10 amostras na realimentação da rede. Para configurações com mais recursos, não foram observadas melhorias significativas no ruído. No entanto, houve um aumento no tempo de treinamento e uma maior demanda de processamento computacional. A Fig. 14 apresenta a análise LOFAR do sinal gerado pela rede treinada.

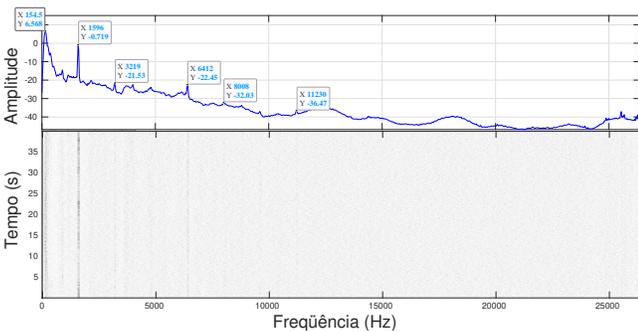


Figura 14: Análise LOFAR do sinal gerado pelo treinamento da rede NARX.

A comparação espectral entre o sinal experimental e o sinal gerado durante o treinamento da rede NARX é ilustrada na Fig. 15. A rede treinada obteve sucesso ao aproximar os tons espectrais da maquinaria gerados pelo simulador fenomenológico, assim como o decaimento do espectro. Notam-se os harmônicos de 77 e 154,5 Hz, nos quais a rede NARX atenuou

o componente de 77 Hz e amplificou o componente de 154,5 Hz, aproximando esses tons espectrais do comportamento do sinal experimental.

Entretanto, a partir da frequência de 4.000 Hz, o comportamento espectral do sinal gerado pela rede treinada começou a divergir do sinal experimental. O valor médio de \bar{E}_{har} entre os picos dos harmônicos do sinal experimental e do sinal fenomenológico foi de 0,6%, enquanto o valor médio de \bar{E}_{amp} foi de 4,15 dB. Além disso, a medida de distância $d(F_q, Fx_q)$ foi de 0,60.

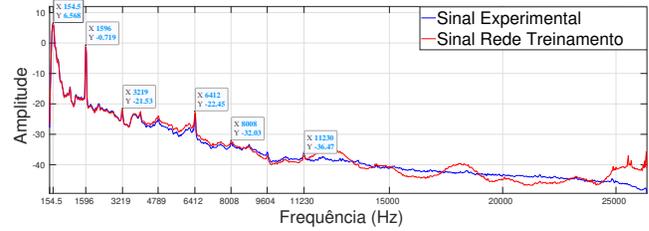


Figura 15: Comparação do sinal experimental e do sinal gerado pelo treinamento da rede.

A Fig. 16 exibe os *boxplots* das métricas de avaliação referentes aos sinais gerados pelas redes treinadas. Foram avaliados o \bar{E}_{amp} e $d(F_q, Fx_q)$.

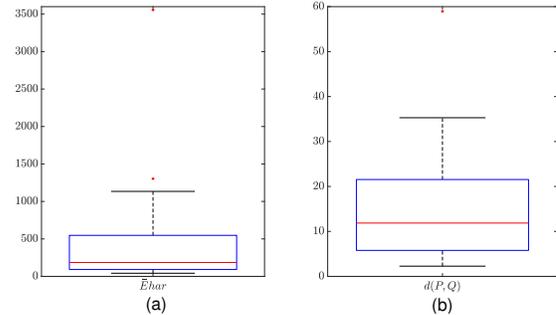


Figura 16: *Boxplots* das métricas de avaliação das redes treinadas: (a) erro absoluto médio e (b) Distância de Wasserstein.

Após a conclusão do treinamento, procedeu-se à avaliação das redes previamente treinadas utilizando um novo sinal simulado pelo módulo fenomenológico. O objetivo dessa avaliação é verificar o desempenho de cada rede, uma vez que, após o treinamento, não serão feitos mais ajustes nos pesos e nenhum ruído de referência será fornecido para comparação.

A rede que forneceu o melhor resultado no teste foi a rede com 4 neurônios, atraso de 10 amostras tanto na camada de entrada quanto na realimentação da rede. A Fig. 17 apresenta a análise LOFAR do sinal gerado no teste da rede treinada. O valor médio de \bar{E}_{har} entre os picos dos harmônicos do sinal experimental e do sinal fenomenológico foi de 8,19%, o valor médio de \bar{E}_{amp} foi de 42,14 dB e a medida de distância $d(F_q, Fx_q)$ foi de 2,27. Ao comparar esses resultados com os obtidos durante o treinamento da rede, nota-se uma diminuição no desempenho da mesma durante o teste, uma vez que não havia o sinal experimental como referência para a avaliação.

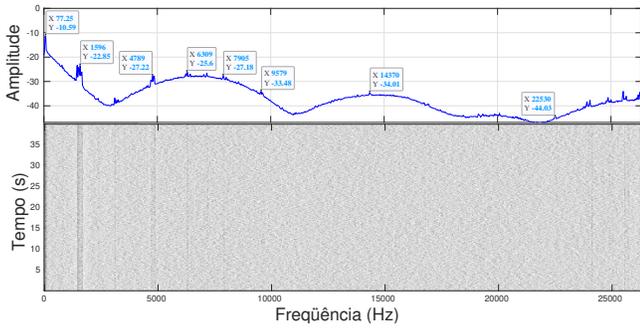


Figura 17: Análise LOFAR do sinal gerado no teste da rede já treinada.

A Fig. 18 mostra a comparação entre as PSDs do sinal experimental e do sinal obtido durante o teste da rede NARX. É evidente que a rede conseguiu preservar os tons espectrais do sinal simulado pelo simulador fenomenológico. No entanto, é importante ressaltar que, ao contrário do treinamento da rede, os componentes de frequência de 77 e 154,5 Hz não foram alterados. Além disso, é importante notar que o comportamento espectral do sinal gerado pela rede não se assemelha ao do sinal experimental.

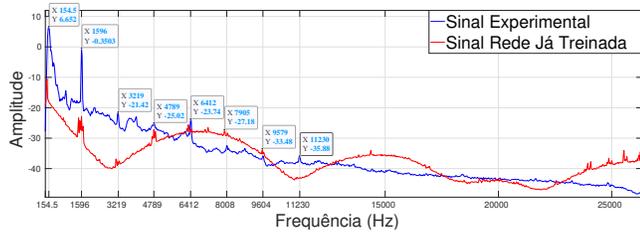


Figura 18: Comparação do sinal experimental e do sinal gerado pelo teste da rede.

Após avaliar o desempenho das redes treinadas e testadas, verificou-se que as medidas de avaliação escolhidas para este estudo não ofereceram uma distinção clara da rede que obteve o melhor resultado. A Fig. 19 representa a comparação da PSD entre o sinal experimental e a PSD da rede NARX, com uma configuração que inclui 3 neurônios, um atraso de 40 amostras na camada de entrada e 50 amostras na realimentação da rede.

A média do valor de \bar{E}_{har} entre os picos dos harmônicos do sinal experimental e do sinal fenomenológico foi de 9,16%, enquanto o valor médio de \bar{E}_{amp} foi de 16,56 dB. Além disso, a medida de distância $d(F_q, Fx_q)$ foi registrada como 316,38, desempenho inferior quando comparado com o teste da rede com 4 neurônios, atraso de 30 amostras na camada de entrada e 10 amostras na realimentação. Embora a análise de desempenho indique que essa configuração resultou em um desempenho inferior, é importante destacar que o comportamento espectral do sinal gerado durante o teste da rede assemelha-se mais ao sinal experimental. É digno de nota que a rede obteve resultados melhores para os componentes de frequência de 77 e 154,5 Hz.

A Fig. 20 exibe os boxplots das medidas de avaliação referentes aos sinais gerados durante o teste da rede NARX.

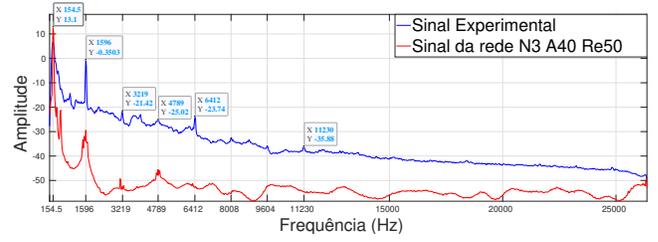


Figura 19: Análise LOFAR do sinal gerado no teste da rede configurada com 3 neurônios, atraso de 40 amostras na camada de entrada e 50 amostras na realimentação da rede.

Foram avaliados o \bar{E}_{amp} e $d(F_q, Fx_q)$.

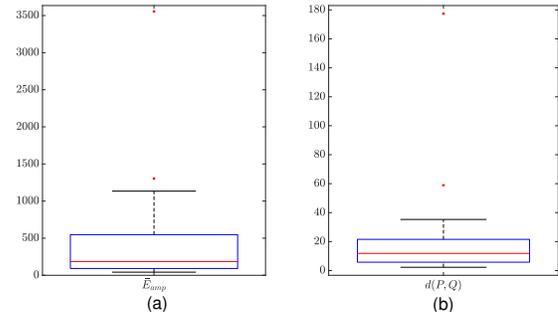


Figura 20: Boxplots das medidas de avaliação do teste das redes já treinadas: (a) erro absoluto médio e (b) Distância de Wasserstein.

VII. CONCLUSÕES

O propósito deste projeto foi criar um sistema para a síntese de ruídos acústicos submarinos, com foco específico no ruído gerado por máquinas de embarcações. Inicialmente, utilizamos um simulador fenomenológico para gerar um ruído com base em dados de uma embarcação de navio de cruzeiro. A análise LOFAR dos resultados demonstrou que o simulador fenomenológico é capaz de simular um ruído de cavitação com características espectrais próximas às especificações fornecidas ao simulador.

Posteriormente, visando aprimorar a semelhança entre o ruído fenomenológico e o ruído experimental, procedemos à integração de uma rede neural NARX ao simulador. Durante o treinamento, a rede neural obteve resultados satisfatórios. Contudo, seu desempenho foi reduzido durante a fase de teste, na qual não são fornecidos sinais de referência nem atualizações nos pesos da camada oculta.

Analisando os resultados das medidas de avaliação dos sinais gerados nos testes das redes, foi observado que as redes com configurações mais elevadas (dentro da faixa considerada) produziram resultados superiores, embora tenha havido um aumento na demanda de processamento do computador. No entanto, as medidas utilizadas neste estudo não conseguiram mensurar efetivamente a eficiência do desempenho das redes, uma vez que não levaram em consideração o comportamento espectral dos sinais.

Como perspectivas para estudos posteriores, sugere-se a incorporação de outras topologias de aprendizado de máquina

visando o aprimoramento do simulador de ruído acústico, como por exemplo, inserir camadas convolucionais como etapa inicial da rede projetada. Adicionalmente, é crucial buscar métodos mais eficazes para avaliar o desempenho das redes, bem como os resultados alcançados, implementando outras métricas para avaliação dos resultados.

Para futuras pesquisas, sugere-se a exploração de tipo de topologias de aprendizado de máquina, a fim de aprimorar o simulador de ruído acústico. Por exemplo, uma abordagem promissora seria incorporar camadas convolucionais como ponto de partida na estrutura da rede. Além disso, é essencial investigar métodos mais eficazes para a avaliação do desempenho das redes e dos resultados obtidos. Isso poderia incluir a implementação de métricas adicionais para uma avaliação mais abrangente dos resultados.

AGRADECIMENTOS

Os autores agradecem ao CNPq, à FAPESB e FAPERJ pelo apoio financeiro. Agradecemos também à Marinha do Brasil e à Universidade de Vigo pelos dados experimentais disponibilizados para execução deste trabalho.

REFERÊNCIAS

- [1] P. C. Etter, *Underwater acoustic modeling and simulation*. CRC press, 2018.
- [2] Z. Wei, Z. Duan, and Y. Han, "Target tracking with asynchronous multi-rate active and passive sonars," in *2021 International Conference on Control, Automation and Information Sciences (ICCAIS)*, 2021, pp. 717–722.
- [3] Z. Cui, H. Zhu, C. Chen, W. Liu, Q. Wang, and Z. Chai, "Study on fish resource assessment method based on imaging sonar," in *2022 3rd International Conference on Geology, Mapping and Remote Sensing (ICGMRS)*, 2022, pp. 327–331.
- [4] L. Li, Y. Li, J. Zeng, G. Xu, Y. Zhang, and X. Feng, "A research of target passive tracking method based on multiple autonomous underwater vehicles," in *2022 International Conference on Innovations and Development of Information Technologies and Robotics (IDITR)*, 2022, pp. 11–16.
- [5] O. Lopera Tellez, "Underwater threat recognition: Are automatic target classification algorithms going to replace expert human operators in the near future?" in *OCEANS 2019 - Marseille*, 2019, pp. 1–4.
- [6] J. d. C. V. Fernandes, N. N. de Moura Junior, and J. M. de Seixas, "Deep learning models for passive sonar signal classification of military data," *Remote Sensing*, vol. 14, no. 11, 2022.
- [7] 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.
- [8] M. Zhou, J. Wang, X. Feng, H. Sun, J. Li, and X. Kuai, "On generative-adversarial-network-based underwater acoustic noise modeling," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 9, pp. 9555–9559, 2021.
- [9] Z. Song, L. Lanrui, Z. Xinhua, Z. Dawei, and L. Mingyuan, "Simulation of backscatter signal of submarine target based on spatial distribution characteristics of target intensity," in *2021 OES China Ocean Acoustics (COA)*, 2021, pp. 234–239.
- [10] W. Zhang, X. Yang, C. Leng, J. Wang, and S. Mao, "Modulation recognition of underwater acoustic signals using deep hybrid neural networks," *IEEE Transactions on Wireless Communications*, vol. 21, no. 8, pp. 5977–5988, 2022.
- [11] A. D. Santos, E. P. S. Filho, E. F. Simas Filho, A. C. L. Fernandes Jr., and J. M. de Seixas, "Simulador de ruído de cavitação de embarcações utilizando uma rede neural realimentada," in *Anais do 15 Congresso Brasileiro de Inteligência Computacional*. Joinville, SC: SBIC, 2021, pp. 1–8.
- [12] P. G. Dylejko, I. R. MacGillivray, S. M. Moore, and A. T. Skvortsov, "The influence of internal resonances from machinery mounts on radiated noise from ships," *IEEE Journal of Oceanic Engineering*, vol. 42, no. 2, pp. 399–409, 2017.
- [13] R. P. Hodges, *Underwater Acoustics Analysis, Design and Performance of SONAR*. Reino Unido: John Wiley and Sons, Ltd, 2010.
- [14] R. Fischer, L. Boroditsky, R. Dempsey, N. Jones, and M. Bahtiarian, "Airborne noise flanking of shipboard vibration isolation systems," *Sound vibration*, vol. 40, 12 2006.
- [15] Ø. S. Pettersen, "A study of radiated noise from fishing vessels," Master's thesis, NTNU, 2017.
- [16] N. N., "Analysis of piston slap motion," *International Journal of Applied Mechanics and Engineering*, vol. 20, 05 2015.
- [17] N. H. Bach, V. D. Nguyen, and L. H. Vu, "Improving the classification of propeller ships using lofar and triple loss variational auto encoder," in *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, 2022, pp. 1–5.
- [18] C. C. Aggarwal, "Neural networks and deep learning," *Springer*, vol. 10, pp. 978–3, 2018.
- [19] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2017.
- [20] D. Wójcik, T. Rymarczyk, Maciura, M. Oleszek, and P. Adamkiewicz, "Time series recognition with convolutional and recursive neural networks in bspm," in *2023 International Interdisciplinary PhD Workshop (IIPhDW)*, 2023, pp. 1–6.
- [21] 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.
- [22] I. Gloza, "Vibration and radiated noise of a small ship," *Hydroacoustics*, vol. 11, pp. 87–96, 2008.
- [23] 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.
- [24] A. M. Dewi, Tulus, and M. Zarlis, "Optimization of smooth support vector machine algorithm using backpropagation nguyen widrow algorithm in classification of mellitus diabetes disease," in *2020 3rd International Conference on Mechanical, Electronics, Computer, and Industrial Technology (MECnIT)*, 2020, pp. 132–136.
- [25] "Image of the vessel MSC Opera," 2023, Accessed: 08-23-23. [Online]. Available: <http://atlantic.uvigo.es/underwaternoise/buscar.php/>