



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

ELIO PITHON SARNO FILHO

TESE DE DOUTORADO

**PROCESSAMENTO DE SINAIS DE SONAR PASSIVO
UTILIZANDO A TRANSFORMADA DE
HILBERT-HUANG COM REDUÇÃO INTELIGENTE DO
RUÍDO**

Salvador

2023

ELIO PITHON SARNO FILHO

**PROCESSAMENTO DE SINAIS DE SONAR PASSIVO
UTILIZANDO A TRANSFORMADA DE HILBERT-HUANG COM
REDUÇÃO INTELIGENTE DO RUÍDO**

TESE DE DOUTORADO

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, PPGEE, da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientadores: Prof. Dr. Eduardo F. de Simas Filho e Prof. Dr. Antônio C. L. Fernandes Jr.

Salvador

2023

S246 Sarno Filho, Elio Pithon.

Processamento de sinais de sonar passivo utilizando a transformada de Hilbert-Huang com redução inteligente do ruído / Elio Pithon Sarno Filho. – Salvador, 2023.

168f.: il. color.

Orientadores: Prof. Dr. Eduardo F. de Simas Filho.

Prof. Dr. Antônio C. L. Fernandes Jr.

Tese (doutorado) – Universidade Federal da Bahia. Escola Politécnica, 2023.

1. Processamento de sinais. 2. Transformada de Hilbert-Huang. 3. Sonar passivo. 4. Acústica submarina. I. Simas Filho, Eduardo F. de. II. Fernandes Jr., Antônio C. L. III. Universidade Federal da Bahia. IV. Título.

CDD: 621.382

Elio Pithon Sarno Filho

**PROCESSAMENTO DE SINAIS DE SONAR PASSIVO
UTILIZANDO A TRANSFORMADA DE HILBERT-HUANG COM
REDUÇÃO INTELIGENTE DO RUÍDO**

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, PPGEE, da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Banca Avaliadora:




Prof. Dr. Eduardo Furtado de Simas Filho
Orientador (PPGEE/UFBA)

Documento assinado digitalmente
gov.br ANTONIO CARLOS LOPES FERNANDES JUI
Data: 20/06/2023 22:38:47-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Antônio Carlos Lopes
Fernandes Jr.**
Coorientador (PPGEE/UFBA)



Prof. Dr. Levy Boccato
FEEC/UNICAMP



Prof. Dr. Natanael Nunes de Moura Jr.
PEE/COPPE/UFRJ



Prof. Dr. Paulo Cesar M. de Abreu Farias
(PPGEE/UFBA)



Prof. Dr. Ricardo Araújo Rios
(PGCOMP/UFBA)

*Dedico esse trabalho aos meus pais e à minha companheira Solange,
que são meus grandes incentivadores e orientadores.*

Agradecimentos

Em primeiro lugar, agradeço à Mãe Natureza, origem, processo e destino de tudo que existe formal e funcionalmente. É Ela que gera e sustenta toda a vida em nosso planeta.

Aos meus pais Elio e Tereza, pelo amor e paciência com que me educaram, sempre indicando um caminho honrado e evolucionário a ser seguido. Em especial, agradeço à Solange, minha esposa amada e leal companheira, com quem venho compartilhando os momentos mais significativos da minha jornada. Ao meu honrado e delicado sogro Orié, minha digníssima sogra Leonilda, meu esforçado cunhado Paulo e minha querida tia Severina. Aos meus irmãos Enio, Leila e Kátia, pelo carinho e apoio incondicionais que sempre me dedicaram ao longo de nossas vidas. Aos meus inesquecíveis e amados avós Vicente, Lelinha, Luís e, em especial, à minha querida e adorada voinha Maria. Agradeço às minhas amadas sobrinhas Tereza, Fernanda, Joana e, em especial, à minha afilhada Juliana e seu valioso marido João. Também agradeço aos meus cunhados Lino e Heiko. À minha querida tia e madrinha Léa, a tio Pedro, meu grande exemplo e incentivador em seguir o caminho acadêmico, e às suas filhas, minhas primas Cristina e Beth. Um agradecimento especial às irmãs de coração Nice, Temilse e Mara, pelo carinho e cuidados que sempre dedicaram à minha família.

Agradeço aos meus orientadores Prof. Eduardo Simas e Prof. Antônio Carlos Fernandes, como também aos inestimáveis Prof. José Manoel de Seixas e Prof. Natanael Moura, pelas sugestões, discussões e correções ao longo deste trabalho de pesquisa. Um agradecimento especial ao grande companheiro Anderson Damacena, sempre presente, conversando, sugerindo e apoiando durante toda a pesquisa. Também agradeço aos professores Paulo César Farias e Wagner Oliveira, e a todo pessoal do Laboratório de Sistemas Digitais da UFBA, meus amigos Edmar, Juan, Moisés, Ricardo, Manoel, Igo e Marton.

Não posso deixar de agradecer ao Prof. Yuzo Iano, meu orientador de mestrado e grande incentivador em permanecer na Academia e na pesquisa, e a todos professores e incentivadores da Unicamp: Prof. Mohamed Habib, Prof. Wilmar Bueno, Prof. Luís Carlos Kretly, Prof. João Romano, Prof. José Raimundo, Prof. Amauri Lopes, Prof. Clésio Tozzi e Prof. Antônio Vivaldi, pelos valiosos ensinamentos mas, principalmente, pelo exemplo de dedicação à vida acadêmica, sempre educando e incentivando tantos jovens, plantando e cuidando de tantas sementes humanas.

Este trabalho é fruto de muita conversa, trocas e aprendizado com pessoas queridas que muito admiro e tantas outras que conheci ao longo do caminho. Portanto, não posso deixar de agradecer a meu grande amigo e irmão mais experiente Edson Gusela, a Eduardo Bastos, Henrique Pithon, Fábio Santos e Joaquin Guanaes, meus amigos e companheiros desde a juventude. Um grande abraço e agradecimento ao grande amigo Valter Cruz, sempre bem humorado, a esbanjar alegria e muito otimismo. Também não poderia deixar de lembrar dos meus queridos mestres Prof. Tomio Kikuchi e D. Bernadette Kikuchi e toda sua família, como também os meus grandes amigos do CIAEV, Célia e Toni Nogueira, Júlio Cesário, Johni Pazin, Kajita e Gilberto Ballod.

Agradeço à FAPESB, pelo suporte financeiro.

Resumo

A tecnologia científica oceânica desempenha um papel chave na área militar e na exploração do ambiente marinho, fato este que vem incentivando o desenvolvimento de novos métodos de processamento e análise de sinais acústicos submarinos. No caso específico do sistema de SONAR (***S**Ound **N**avigation and **R**anging*) passivo, a maioria das técnicas utilizadas na detecção e classificação de embarcações em operações militares com submarinos se baseia na transformada de Fourier de tempo curto (*short-time Fourier transform* – STFT). No entanto, este método de análise espectral possui limitações quanto às resoluções tempo-frequência (*time-frequency* – TF), o que afeta diretamente o desempenho na estimação dos parâmetros característicos de uma embarcação, como também no monitoramento do seu comportamento dinâmico. No presente trabalho de doutorado, é proposta uma ferramenta de análise espectral com redução de ruído baseada na técnica denominada transformada Hilbert-Huang (*Hilbert-Huang transform* – HHT). O método proposto tem como objetivo central, ser utilizado em conjunto à Detecção de Modulação de Envoltória em Ruído (*Detection of Envelope Modulation on Noise* – DEMON), tradicionalmente utilizada na análise de sinais de SONAR passivo. Para o referido propósito, foi realizada uma sequência de três estudos visando, no primeiro deles, a escolha da variante HHT a ser usada em substituição à STFT, utilizada na análise DEMON tradicional. Em seguida, realizou-se a investigação e seleção de uma técnica de redução de ruído para a mitigação deste grave problema associado à análise de sinais de SONAR passivo experimentais e, finalmente, a implementação da ferramenta proposta, com base na variante HHT escolhida e em um sistema inteligente de classificação. Os resultados da aplicação desse novo método em sinais simulados e experimentais de SONAR passivo indicam um melhor desempenho quando comparados aos obtidos com a análise DEMON tradicional, ao apresentar uma maior precisão e eficiência na análise de parâmetros estáticos e dinâmicos de embarcações. Quando aplicados a sinais experimentais, o método proposto mostrou ter uma maior resolução de frequência, com uma largura espectral média cerca de 28 vezes menor, além de apresentar uma relação sinal-ruído média 87,8 dB maior. Além disso, na avaliação de desempenho, o classificador inteligente obteve uma acurácia de 95%, uma taxa de falsos positivos de 3,2% e uma área sob a curva (*Area Under Curve* – AUC) de 97,8%.

Abstract

Ocean science technology plays a key role in military and exploration of the marine environment, a fact that has been encouraging the development of new methods of processing and analysis of underwater acoustic signals (UAS). In the specific case of the passive SONAR (**SO**und **NA**vigation and **R**anging) system, most techniques used in detection and classification of vessels in military operations with submarines are based on the short-time Fourier transform (STFT). However, this spectral analysis method has limitations regarding time-frequency (TF) resolution, which directly affects the performance in estimating the characteristic parameters of a vessel, as well as monitoring its dynamic behavior. This doctoral work proposes a spectral analysis tool with noise reduction based on the technique called Hilbert-Huang transform (HHT). The main objective of the proposed method is to be used in conjunction with the Detection of Envelope Modulation on Noise (DEMON), traditionally used in the analysis of passive SONAR signals. For that, a sequence of three studies was carried out. The aim of the first study was the choice of the variant HHT to be used instead of STFT, which is used in traditional DEMON analysis. In the following, the investigation and selection of a noise reduction technique to mitigate this serious problem associated with the analysis of experimental passive SONAR signals was carried out and, finally, we implemented the proposed tool, based on the chosen HHT variant and an intelligent classification system. The results of applying this new method to simulated and experimental passive SONAR signals indicate a better performance when compared to those obtained with the traditional DEMON analysis, by presenting greater precision and efficiency in the analysis of static and dynamic parameters of vessels. When applied to experimental signals, the proposed method achieved a higher frequency resolution, with an average spectral width of about 28 times smaller, in addition to presenting an average signal-to-noise ratio of 87,8 dB bigger. Furthermore, in the performance evaluation, the intelligent classifier obtained an accuracy of 95%, a false positive rate (FPR) of 3,2% and an area under curve (AUC) of 97,8%.

Lista de ilustrações

Figura 1 – Cenário típico de rastreamento de dois contatos por um sistema de SONAR passivo de um submarino: (a) Cenário (adaptação de [78]) e (b) Arranjo cilíndrico de hidrofones utilizado (Fonte: [1])	6
Figura 2 – Ilustração do ruído irradiado por embarcações: (a) Formação de bolhas de ar no processo de cavitação (Fonte: [11]) e (b) Espectro de potência (Fonte: [78]).	7
Figura 3 – Espectros de amplitude referentes a fontes típicas de ruído acústico ambiental: (a) estado do mar e (b) chuva (gráficos implementados com base nos dados de [84])	8
Figura 4 – Diagrama de blocos da análise DEMON.	9
Figura 5 – Diagrama de blocos da transformada Hilbert-Huang (HHT).	11
Figura 6 – Resultados da análise DEMON e da HHT-EMD de um sinal de SONAR passivo: (a) sinal no domínio do tempo; (b) espectrograma; (c) PSD média normalizada $\bar{P}(f)$; (d) IMFs resultantes da aplicação da EMD; (e) HS e (f) MHS (Fonte: Marinha do Brasil).	17
Figura 7 – Espectro de frequência da wavelet Bark com 10 subbandas.	24
Figura 8 – Ilustração do hiperplano ótimo de decisão H_0 do classificador SVM. São indicados os vetores-suporte e as margens de separação (adaptado de [41]). .	28
Figura 9 – Diagrama de blocos da análise DEMON padrão, indicando uma possível substituição da STFT pela HHT-EMD.	31
Figura 10 – Cenário de aquisição do conjunto 1 de sinais experimentais da Marinha do Brasil [246]: (a) Vista panorâmica da Baía da Guanabara (Rio de Janeiro), mostrando a passagem do navio <i>offshore</i> , que cruza com uma embarcação de pequeno porte; (b) Arranjo de hidrofones e (c) Posicionamento do arranjo de hidrofones em relação ao navio.	34
Figura 11 – Cenário de aquisição do conjunto de sinais experimentais do banco de dados <i>ShipsEar</i> [245].	34
Figura 12 – Resultados da aplicação da DEMON aos sinais experimentais da Marinha do Brasil (espectrograma à esquerda e $\bar{P}(f)$ à direita): (a) <i>Array</i> Elíptico (Baía de Guanabara), (b) <i>Array</i> Cilíndrico (M190) e (c) <i>Array</i> Cilíndrico (M205). .	35
Figura 13 – Análise DEMON do sinal acústico da balsa de passageiros Mar de Onza (banco de dados <i>ShipsEar</i> [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\bar{P}(f)$	36
Figura 14 – Análise DEMON do sinal acústico da balsa de passageiros Mar de Cangas (banco de dados <i>ShipsEar</i> [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\bar{P}(f)$	36
Figura 15 – Análise DEMON do sinal acústico do navio de carga refrigerado Eimskip Reefer (banco de dados <i>ShipsEar</i> [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\bar{P}(f)$	37

Figura 16 – Resultados da aplicação da DEMON ao sinal simulado com SS0, baseado no sinal experimental da Marinha do Brasil, pertencente ao conjunto 1 (espectrograma à esquerda e $\overline{P}(f)$ à direita).	38
Figura 17 – Resultados da aplicação da análise DEMON ao sinal acústico do navio de carga refrigerado Eimskip Reefer e à sua versão simulada (espectrograma à esquerda e $\overline{P}(f)$ à direita): (a) Sinal experimental (banco de dados <i>ShipsEar</i> [247]) e (b) Sinal simulado.	39
Figura 18 – Espectro de potência de um sinal genérico de SONAR passivo, com quatro componentes de frequência ($N_h = 4$), indicando os parâmetros gráficos usados no cálculo de $\overline{\Delta F}_{3dB}$ e $\overline{SNR}$	41
Figura 19 – Diagrama de blocos da DEMON-HHT: (a) Diagrama geral; (b) Detalhes internos do super-bloco HHT.	43
Figura 20 – Diagrama de blocos da análise DEMON.	43
Figura 21 – Diagrama detalhado do super-bloco HHT, que integra o sistema DEMON-HHT-FILTRO.	44
Figura 22 – Diagrama de blocos geral do sistema proposto EMD-IRNI.	46
Figura 23 – Diagrama de blocos detalhado do seletor de IMFs.	46
Figura 24 – Ilustração de um sistema binário de classificação com seus possíveis resultados.	49
Figura 25 – Diagrama de blocos da validação cruzada <i>k-fold</i>	52
Figura 26 – Indicação dos subconjuntos de treinamento e de teste usados na sequência de iterações (Fold $i, i = 1, 2, \dots, k$) do processo de validação cruzada <i>k-fold</i> ($k = 5$)	52
Figura 27 – Resultados da aplicação dos métodos ao sinal simulado contaminado por ruído ambiental estado do mar de nível zero (SS0): (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita), (b) HHT-ICEEMDAN (HS à esquerda e MHS à direita), (c) HHT-UPEMD (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).	57
Figura 28 – Resultados dos métodos aplicados ao sinal simulado contaminado por ruído ambiental estado do mar nível SS1: (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita): (b) HHT-UPEMD (HS à esquerda e MHS à direita), (c) HHT-ICEEMDAN (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).	60
Figura 29 – Resultados dos métodos aplicados ao sinal simulado contaminado por ruído ambiental estado do mar nível SS3: (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita): (b) HHT-UPEMD (HS à esquerda e MHS à direita), (c) HHT-ICEEMDAN (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).	61
Figura 30 – Resultados da aplicação da análise DEMON e da HHT-UPEMD ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara, e à sua versão simulada SS0: (a) Análise DEMON ao sinal experimental (espectrograma à esquerda e $\overline{P}(f)$ à direita), (b) Análise DEMON ao sinal simulado (espectrograma à esquerda e $\overline{P}(f)$ à direita), (c) HHT-UPEMD ao sinal experimental (HS à esquerda e MHS à direita) e d) HHT-UPEMD ao sinal simulado (HS à esquerda e MHS à direita).	63

- Figura 31 – Resultados da aplicação da HHT-ICEEMDAN e da HHT-VMD ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara, e à sua versão simulada SS0 (HS à esquerda e MHS à direita): (a) HHT-ICEEMDAN ao sinal experimental, (b) HHT-ICEEMDAN ao sinal simulado, (c) HHT-VMD ao sinal experimental e (d) HHT-VMD ao sinal simulado. 64
- Figura 32 – Resultados dos métodos aplicados ao sinal experimental produzido pela embarcação Eimskip Reefer (banco de dados *ShipsEar* [247]): (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita), (b) HHT-UPEMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita) e (c) HHT-VMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita). 67
- Figura 33 – Resultados dos métodos aplicados à versão simulada do sinal experimental produzido pela embarcação Eimskip Reefer (banco de dados *ShipsEar* [242]): (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita), (b) HHT-UPEMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita) e (c) HHT-VMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita). 68
- Figura 34 – Resultados da aplicação da análise DEMON (esquerda) e da HHT-UPEMD (direita) ao sinal experimental do navio de passageiros que sai do Porto de Vigo (Espanha). No topo (escala de frequência normal): espectrograma (esquerda) e HS (direita). Na parte inferior (escala de frequência expandida): espectrograma (esquerda) e HS (direita). 70
- Figura 35 – Resultados da aplicação da análise DEMON (esquerda) e da HHT-UPEMD (direita) ao sinal experimental do navio de passageiros que chega ao Porto de Vigo (Espanha). No topo (escala de frequência normal): espectrograma (esquerda) e HS (direita). Na parte inferior (escala de frequência expandida): espectrograma (esquerda) e HS (direita). 70
- Figura 36 – Resultados da aplicação da HHT-VMD aos sinais experimentais dos navios de passageiros que sai (esquerda) e chega (direita) ao Porto de Vigo (Espanha). No topo, HS em escala de frequência normal. Na parte inferior, HS em escala de frequência expandida. 71
- Figura 37 – Resultados dos métodos aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) HHT-UPEMD ao sinal original (IMFs ruidosas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito), (b) HHT-UPEMD ao sinal sem ruído (IMFs filtradas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito) e (c) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita). 73

Figura 38 – Resultados dos métodos aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) HHT-VMD ao sinal original (IMFs ruidosas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito), (b) HHT-UPEMD ao sinal sem ruído (IMFs filtradas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito) e (c) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita).	74
Figura 39 – Resultados da WTD-UPEMD-SWT aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).	77
Figura 40 – Resultados da WTD-VMD-SWT aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).	77
Figura 41 – Resultados da HHT-UPEMD-BWTD aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).	78
Figura 42 – Resultados da HHT-VMD-BWTD aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).	78
Figura 43 – Curvas ROC dos cinco atributos para as configurações de hiperparâmetros da Tabela 12. Em cada curva é indicado o ponto ótimo de operação, com o valor de TFP correspondente a $TVP = 90\%$	81
Figura 44 – <i>Boxplots</i> das distribuições de valores dos parâmetros de desempenho para a combinação de atributos {ACF, PE, SE, PR, MI}, com os <i>DiscrimType</i> linear e quadrático. São indicados os valores medianos: (a) Acurácia (ACC), (b) TVP, (c) TFP e (d) AUC.	82
Figura 45 – <i>Boxplots</i> das distribuições de valores médios dos parâmetros de desempenho para as várias combinações de atributos, com o <i>DiscrimType</i> quadrático: (a) Acurácia (ACC), (b) TVP, (c) TFP e (d) AUC.	83
Figura 46 – Curvas dos valores medianos das distribuições dos parâmetros de desempenho, obtidos para a combinação de atributos {ACF, SE}. Os gráficos correspondem a 4 valores de BC (1, 3, 5 e 7), valores de KS (na faixa $[0, 1 - 3, 0]$ e à função <i>kernel</i> Gaussiana. São indicados os valores dos parâmetros com melhor desempenho (máximos ou mínimos): (a) ACC; (b) TVP e (c) TFP.	86
Figura 47 – Curvas ROC dos classificadores SVM e FDA e dos cinco atributos individuais. Em cada curva é indicado o ponto ótimo de operação, com o valor de TFP correspondente a $TVP = 90\%$	88
Figura 48 – Distribuições de valores da ACC e TVP dos classificadores SVM e FDA e dos atributos individuais, com indicação dos valores medianos (SVM e FDA) e máximo de cada atributo: (a) ACC e (b) TVP.	88
Figura 49 – Distribuições de valores da TFP e AUC dos classificadores SVM e FDA e dos atributos individuais, com detalhes em escala expandida e indicação dos valores máximo (mínimo): (a) TFP e (b) AUC.	89

Figura 50 – Resultados do processamento pelo EMD-IRNI do sinal 6: (a) Entradas do seletor de IMFs, (b) Saídas do seletor de IMFs, (c) PSD média normalizada $\overline{P}(f)$ (análise DEMON) e (d) MHS.	91
Figura 51 – Resultados do processamento pelo EMD-IRNI do sinal 33: (a) Entradas do seletor de IMFs, (b) Saídas do seletor de IMFs, (c) PSD média normalizada $\overline{P}(f)$ (análise DEMON) e (d) MHS.	92
Figura 52 – Distribuições de valores da mediana ACF, obtidos no processamento, pelo EMD-IRNI, de dois entre os 10 sinais experimentais, em que ocorreram erros de classificação: (a) Sinal 6 e (b) Sinal 33.	94
Figura 53 – Resultados da avaliação de eficiência de detecção do EMD-IRNI aplicado ao conjunto de 40 sinais experimentais e à sua versão simulada: (a) Taxa de detecção do EMD-IRNI; (b) Acurácia de estimação de frequência ($\overline{\Delta F}_p$) do EMD-IRNI e (c) Acurácia $\overline{\Delta F}_p$ da análise DEMON padrão (simulados). . . .	96
Figura 54 – Resultados dos métodos da pesquisa com melhores desempenhos, aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) Análise DEMON (espectrograma à esquerda e $\overline{P}(f)$ à direita), (b) HHT-VMD (HS à esquerda e MHS à direita), c) HHT-VMD-BWTD (HS à esquerda e MHS à direita) e (d) EMD-IRNI (HS à esquerda e MHS à direita). . . .	99
Figura 55 – Resultados da avaliação de eficiência de detecção dos métodos com melhor desempenho nos três estudos de caso e da DEMON padrão, quando aplicados ao conjunto de 40 sinais experimentais e à sua versão simulada: (a) Taxa de detecção; (b) Acurácia de estimação de frequência ($\overline{\Delta F}_p$).	100
Figura 56 – Distribuição dos coeficientes wavelet Bark de uma IMF-T na 50 ^a sub-banda: (a) Espectro de amplitude da IMF-T; (b) Histograma dos coeficientes; (c) Boxplot dos coeficientes.	134
Figura 57 – Distribuição dos coeficientes wavelet Bark de uma IMF-R na 50 ^a sub-banda: (a) Espectro de amplitude da IMF-R; (b) Histograma dos coeficientes; (c) Boxplot dos coeficientes.	134
Figura 58 – Distribuição dos coeficientes wavelet Bark do sinal analisado $x[n]$ na 50 ^a sub-banda.: (a) Histograma dos coeficientes; (b) Boxplot dos coeficientes. . . .	135
Figura 59 – Conjunto de IMFs relativas a um sinal experimental genérico, com indicação dos componentes-significativos H_i ($i = 1, 2, \dots, 6$).	138
Figura 60 – Conjunto de IMFs relativas a um sinal experimental genérico, com indicação dos componentes-referência, que apresentam amplitudes y_i dB/rpm ($i = 1, 2, \dots, 7$). . . .	138

Lista de tabelas

Tabela 1 – Informações dos sinais experimentais	37
Tabela 2 – Parâmetros de desempenho de classificação, em que as quantidades de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos são indicadas por VP, VN, FP e FN, respectivamente.	50
Tabela 3 – Faixas de valores dos hiperparâmetros utilizadas no processo de seleção dos limiares de classificação. São válidas para os cinco atributos.	51
Tabela 4 – Hiperparâmetro usado no treinamento e validação dos classificadores FDA. .	53
Tabela 5 – Hiperparâmetros usados no treinamento e validação dos classificadores SVM	53
Tabela 6 – Medidas de desempenho para os diferentes métodos de processamento de dados simulados contaminados por ruído ambiental estado do mar de nível zero (SS0). Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.	56
Tabela 7 – Resultados da aplicação dos vários métodos ao sinal simulado contaminado por ruído ambiental estado do mar de vários níveis. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método. Em destaque de cor, os melhores valores dos três parâmetros, obtidos para cada nível de ruído incidente.	59
Tabela 8 – Medidas de desempenho para os diferentes métodos de processamento do sinal experimental da Baía de Guanabara e de sua versão simulada SS0. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.	65
Tabela 9 – Medidas de desempenho para os diferentes métodos de processamento do sinal experimental da Baía de Guanabara. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.	77
Tabela 10 – Faixas de valores dos hiperparâmetros utilizadas no processo de definição dos limiares de classificação. São válidas para os cinco atributos.	80
Tabela 11 – Configurações de hiperparâmetros que proporcionaram os melhores desempenhos, no caso do atributo $\rho_{xx}(\eta)$, Em destaque de cor, é indicada a melhor configuração, com os respectivos valores de FPR e AUC obtidos.	80
Tabela 12 – Configurações de hiperparâmetros que propiciaram o melhor desempenho dos cinco atributos.	81
Tabela 13 – Hiperparâmetros usados no treinamento e validação dos classificadores SVM.	84
Tabela 14 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, PE}, {ACF, SE}, {ACF, PR} e {ACF, MI}.	85
Tabela 15 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, PE, SE}, {ACF, PE, PR}, {ACF, PE, MI} e {ACF, SE, PR}.	85

Tabela 16 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos $\{ACF, SE, MI\}$, $\{ACF, PR, MI\}$, $\{ACF, PE, SE, PR\}$ e $\{ACF, PE, SE, MI\}$	86
Tabela 17 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos $\{ACF, PE, PR, MI\}$, $\{ACF, SE, PR, MI\}$ e $\{ACF, PE, SE, PR, MI\}$	86
Tabela 18 – Conjunto de valores dos Hiperparâmetros do classificador SVM selecionado, juntamente com os valores obtidos dos parâmetros de desempenho.	87
Tabela 19 – Valores dos parâmetros de desempenho das distribuições mostradas nas Figuras 48 e 49: mediana (em vermelho) e IIQ (em azul)	88
Tabela 20 – Valores da SNR_i e de IIQ^{ACF} das cinco IMF_i , ($i = 1, 2, \dots, 5$) dos sinais 6, 9, 14, 15 e 19.	94
Tabela 21 – Valores da SNR_i e de IIQ^{ACF} das cinco IMF_i , ($i = 1, 2, \dots, 5$) dos sinais 29, 33, 35, 36 e 38.	94
Tabela 22 – Medidas de desempenho dos métodos da pesquisa com melhores desempenhos no processamento do sinal experimental da Marinha do Brasil (conjunto 1). Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.	98
Tabela 23 – Valor mediano e do IIQ das distribuições das taxas de detecção e das acurácias de estimação de frequência ($\overline{\Delta F_p}$) dos métodos, mostradas na Figura 55: mediana (em vermelho) e IIQ (em azul).	100
Tabela 24 – Gabarito final (padrão-ouro) resultante da análise realizada pelo especialista.	139

Lista de símbolos

$a_i(t)$	Amplitude instantânea
am^{-1}	Por amostra
b	Frequência Bark
$c_i(t)$	i -ésima IMF
$d_j(t)$	Resíduo da j -ésima iteração de peneiramento
dB	Decibel
dB re $1\mu\text{Pa}$	Decibel relativo a 1×10^{-6} Pascal
<i>DiscrimType</i>	Hiperparâmetro do classificador FDA que define a variante LDA utilizada
$e_{\max}$	Envoltória superior
$e_{\min}$	Envoltória inferior
f	Frequência linear contínua
$f(t)$	Frequência instantânea
$f_i(t)$	Frequência instantânea
F_q	Frequência nominal do q -ésimo componente espectral
$\widehat{F}_q$	Frequência estimada do q -ésimo componente espectral
F_s	Frequência de amostragem
$h_M[k]$	Amplitude do MHS no índice de frequência discreta k
$h_M(\omega)$	Amplitude do MHS na frequência angular contínua ω
Hz	Hertz
$H(\omega, t)$	Espectro global de amplitude de Hilbert (tempo contínuo)
$H[k, n]$	Espectro global de amplitude de Hilbert (tempo discreto)
IMF_i	i -ésima IMF
$\text{IIQ}^{(i)}$	Intervalo interquartil de uma distribuição de valores relativos à IMF_i
J_{ik}	k -ésima janela da IMF_i
k	Índice de frequência discreta

K	Número de iterações do processo de peneiramento
$K_{\max}$	Número máximo de iterações de peneiramento
M	Número total de sub-bandas no domínio Bark
$M_d^{(i)}$	Mediana de uma distribuição de valores relativos à IMF _{<i>i</i>}
n_p	Número total de fases usadas na UPEMD
N	Número total de IMFs
N_J	Número total de janelas da estrutura de quadros J _{<i>ik</i>}
N_h	Número total de componentes espectrais
N_R	Número total de realizações (sorteios) do processo de validação cruzada k-fold
$\overline{P}(f)$	Densidade espectral de potência (PSD) média
N_s	Número total de amostras
$r_N(t)$	Resíduo final da decomposição EMD
rpm	Rotação por minuto
s	Segundo
$s[n]$	Sinal de entrada (tempo discreto)
$\overline{\text{SNR}}$	Relação sinal-ruído média
$S_m^{\text{th}}[k]$	<i>m</i> -ésimo coeficiente wavelet selecionado na BWTD
T	Intervalo de duração do sinal
Thr_m	Limiar de seleção da BWTD
$X(f, i)$	Transformada de Fourier em tempo discreto de $x[n]$ na <i>i</i> -ésima janela temporal
$\overline{X}_F(f)$	média dos trechos de $X_F(f)$
$x[n]$	Sinal pré-processado (tempo discreto)
$x_f[n]$	Sinal pré-processado com ruído reduzido (tempo discreto)
$x(t)$	Sinal pré-processado (tempo contínuo)
$x_{\text{rec}}[n]$	Sinal reconstruído à partir das IMFs
$X_F(f)$	Espectro de frequência do sinal $x[n]$ sem ruído
y_{LIM}	Limiar de seleção da PSD média normalizada $\overline{P}(f)$
$w[n]$	Janela de Hanning

$W_m(b)$	Função wavelet no domínio Bark
$z_i(t)$	Versão analítica da IMF_i
Γ	Número total de realizações aleatórias
Δ	desvio de frequência linear contínua
Δf	Resolução de frequência
$\overline{\Delta F}_p$	Desvio percentual médio de frequência
$\overline{\Delta F}_{3dB}$	Largura espectral média a -3 dB do valor de pico
Δt	Resolução temporal
ε_0	Valor RMS da amplitude do ruído incidente
$\rho_{xx}(\eta)$	Coefficiente da função de autocorrelação (ACF)
$\varphi_i(t)$	Fase instantânea
ω	Frequência angular contínua
$\omega_i(t)$	Frequência angular instantânea

Lista de abreviaturas e siglas

AAPE	<i>Amplitude-Aware Permutation Entropy</i>
ACC	Acurácia
AUC	<i>Area Under Curve</i>
ACF	<i>Autocorrelation Function</i>
AM	<i>Amplitude Modulation</i>
BC	Fator de regularização utilizado no classificador SVM (<i>Box constraint</i>)
BW	<i>Bandwidth</i>
BWF	<i>Bark Wavelet Function</i>
BWTD	<i>Bark Wavelet Threshold Denoising</i>
CHA	<i>Cylindrical Hydrophone Array</i>
CEEMD	<i>Complete Ensemble Empirical Mode Decomposition</i>
CEEMDAN	<i>Complete Ensemble Empirical Mode Decomposition with Adaptive Noise</i>
COPPE	Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia
DEMON	<i>Detection of Envelope Modulation on Noise</i>
DFT	<i>Discrete Fourier Transform</i>
DTFT	<i>Discrete Time Fourier Transform</i>
EMD	<i>Empirical Mode Decomposition</i>
EEMD	<i>Ensemble Empirical Mode Decomposition</i>
EMD-IRNI	<i>EMD Estimation Method with Intelligent Removal of Noisy IMFs</i>
FD	Fator de Decimação
FDA	<i>Fisher Discriminant Analysis</i>
FFT	<i>Fast Fourier Transform</i>
FIR	<i>Finite Impulse Response</i>
FP	Falso positivo
FM	<i>Frequency Modulation</i>

FT	<i>Fourier Transform</i>
HHT	<i>Hilbert-Huang Transform</i>
HHT-EMD	<i>Hilbert-Huang Transform with Empirical Mode Decomposition</i>
HS	<i>Hilbert Spectrum</i>
HT	<i>Hilbert Transform</i>
IA	<i>Instantaneous Amplitude</i>
ICEEMDAN	<i>Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise</i>
IF	<i>Instantaneous Frequency</i>
IMF	<i>Intrinsic Mode Function</i>
IMF _d	IMF _f decimadas
IMF _f	IMFs filtradas
IMF-R	IMF-Ruído
IMF-T	IMF de Transição
IMF-T _f	IMF-T filtradas
IMF _{vmd}	IMF gerada pela VMD
IPqM	Instituto de Pesquisa da Marinha do Brasil
KS	Fator de escala do <i>kernel</i> utilizado no classificador SVM (<i>kernel scale</i>)
LOFAR	LO w F requency and R ecording
MDS	<i>Modal Splitting</i>
MHS	<i>Marginal Hilbert Spectrum</i>
MI	<i>Mutual Information</i>
MM	<i>Mode Mixing</i>
MS-EMD	<i>Empirical Mode Decomposition with Masking Signal</i>
M190	Sinal da Marcação 190° (experimental)
M205	Sinal da Marcação 205° (experimental)
NH	Número de Harmônicos
NMR	Nível Médio de Ruído de Fundo

OL	<i>Overlap</i>
PCC	<i>Pearson Correlation Coefficient</i>
PE	<i>Permutation Entropy</i>
$\bar{P}(f)$	PSD Média Normalizada
PR	<i>Predictivity Ratio</i>
PSD	<i>Power Spectral Density</i>
RMSE	<i>Root-Mean-Square Error</i>
RN	<i>Residual Noise</i>
ROC	<i>Receiver Operating Characteristic</i>
SE	<i>Spectral Entropy</i>
SNR	<i>Signal-to-Noise Ratio</i>
SONAR	SO und NA avigation and R anging
SVM	<i>Support Vector Machine</i>
SWT	<i>Discrete Stationary Wavelet Transform</i>
SS0	<i>Sea State Level 0</i>
SS1	<i>Sea State Level 1</i>
SS3	<i>Sea State Level 3</i>
STFT	<i>Short-Time Fourier Transform</i>
TF	<i>Time-Frequency</i>
TFP	Taxa de Falsos Positivos
TG	Tempo Computacional Gasto
TPSW	<i>Two-Pass Split Window</i>
TPSW-F	TPSW no Domínio da Frequência
TPSW-T	TPSW no Domínio do Tempo
TVP	Taxa de Verdadeiros Positivos
UAS	<i>Underwater Acoustic Signal</i>
UPEMD	<i>Uniform Phase Empirical Mode Decomposition</i>
VA	Variável Aleatória

VMD	<i>Variational Mode Decomposition</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WS	<i>Window size</i>
WSS	<i>Wide-Sense Stationarity</i>
WT	<i>Wavelet Transform</i>
WTD	<i>Wavelet Threshold Denoising</i>
WTD-BWTD	<i>Wavelet Threshold Denoising usando Bark Wavelet Threshold Denoising</i>
WTD-SWT	<i>Wavelet Threshold Denoising usando Discrete Stationary Wavelet Transform</i>
WVD	<i>Wigner-Ville Distribution</i>

Sumário

1	INTRODUÇÃO	1
1.1	Motivação	1
1.2	Objetivos	3
1.3	Contribuições da Tese	4
1.4	Organização do Documento	4
2	REVISÃO DA LITERATURA	5
2.1	Sistemas de SONAR Passivo	5
2.1.1	Ruído acústico submarino	6
2.1.2	Análise DEMON padrão	8
2.2	A Decomposição Empírica em Modos e a Transformada Hilbert-Huang	10
2.2.1	Representação Tempo-Frequência	11
2.2.2	O algoritmo EMD	13
2.2.3	Transformada Hilbert-Huang	18
2.2.4	Comparação entre HS e STFT	19
2.2.5	Variações da EMD	20
2.2.6	Resiliência ao Ruído	21
2.3	Filtragem Wavelet Bark com Limiar	23
2.4	Sistemas de Classificação Binária	25
2.4.1	Análise discriminante de Fisher	26
2.4.2	Máquina de vetores-suporte	27
2.5	Considerações Finais	30
3	MÉTODO PROPOSTO E SINAIS UTILIZADOS	31
3.1	Sinais Utilizados	32
3.1.1	Sinais experimentais	32
3.1.2	Sinais Simulados	37
3.2	Avaliação de desempenho	39
3.3	Estudo de Caso 1 - Aplicação da HHT em substituição à STFT na Análise DEMON	41
3.4	Estudo de Caso 2 - Estratégia de redução de ruído	44
3.5	Estudo de Caso 3 - Sistema Inteligente com redução de ruído	46
3.5.1	Filtragem e pré-filtragem BWTD	47
3.5.2	Extração de atributos	47
3.5.3	Classificador de IMFs	48
4	RESULTADOS	55
4.1	Estudo de Caso 1 - Aplicação da HHT em substituição da STFT na Análise DEMON	55

4.1.1	Desempenho em Sinais Simulados	55
4.1.2	Desempenho em Sinal Experimental	62
4.1.3	Avaliação da Resiliência à Mixagem de Modos	65
4.1.4	Avaliação do Comportamento Dinâmico	69
4.1.5	Considerações sobre o Estudo de Caso 1	71
4.2	Estudo de Caso 2 - Estratégia de redução de ruído	72
4.2.1	Filtragem passa-faixa das IMFs	72
4.2.2	Filtragem WTD das IMFs	75
4.2.3	Considerações sobre o Estudo de Caso 2	79
4.3	Estudo de Caso 3 - Sistema Inteligente com redução de ruído	79
4.3.1	Limiares de classificação	80
4.3.2	Seleção do classificador FDA	81
4.3.3	Seleção do classificador SVM	83
4.3.4	Análise e comparação dos classificadores SVM e FDA	86
4.3.5	Avaliação do EMD-IRNI em operação	89
4.4	Análise comparativa entre os principais resultados dos três estudos de caso	96
5	CONCLUSÕES E PERSPECTIVAS	101
	REFERÊNCIAS	103
	APÊNDICES	123
	APÊNDICE A – TRABALHOS PUBLICADOS	125
A.1	Artigos aprovados em Congressos	125
A.2	Artigo publicado em revista	128
	APÊNDICE B – DECOMPOSIÇÃO EM MODOS VARIACIONAIS	129
	APÊNDICE C – DETALHES DO ESTUDO DE CASO 3	131
C.1	Definição dos atributos	131
C.2	Limiar de Seleção da BWTD	132
C.3	Faixas dos Parâmetros Operacionais	135
	APÊNDICE D – GABARITO ESPECIALISTA	137

1 Introdução

Nas últimas décadas, tem-se observado um avanço crescente das técnicas de detecção e classificação de objetos de interesse no ambiente submarino. Nesse contexto, a utilização de sistemas acústicos como o SONAR (***S**Ound **N**avigation and **R**anging*), se deve ao fato de que as ondas eletromagnéticas são bastante atenuadas no ambiente submarino, enquanto as ondas acústicas conseguem se propagar nesse meio com perdas menores. Em operações militares navais, o sinal acústico gerado por um navio de superfície pode ser usado por um submarino para identificar esse navio e vice-versa [1]. No entanto, o SONAR também tem aplicações em áreas não-militares, tais como no monitoramento da fauna marinha [2, 3], no imageamento do leito submarino [4, 5, 6], na comunicação submarina para veículos não-tripulados [7, 8] e na indústria de pesca moderna [9, 10].

Existem dois tipos de sistemas SONAR: o ativo e o passivo. Em aplicações militares, o SONAR ativo é utilizado por navios para a detecção de submarinos, enquanto o passivo geralmente é utilizado por submarinos. O maior problema da detecção passiva é identificar o sinal de interesse emitido pelo alvo almejado em um ambiente ruidoso, uma vez que o espectro de frequência do ruído se sobrepõe ao do alvo de interesse. Outro problema é a presença de outros alvos que podem interferir no processo de detecção e classificação. Por isso, técnicas de processamento de sinais são necessárias para a melhor caracterização dos sinais de interesse, com o objetivo de melhorar a relação sinal-ruído (*signal to noise ratio* – SNR), permitindo a adequada detecção e classificação dos alvos [1].

1.1 Motivação

Detecção e classificação em um sistema de SONAR passivo podem ser realizadas de forma automática por algoritmos de processamento de sinais e de inteligência computacional para apoiar o operador SONAR [1, 11]. O presente trabalho direciona-se para a busca de uma nova forma de representação e caracterização espectral do sinal de SONAR passivo, baseada na técnica de análise tempo-frequência (*time-frequency* – TF) denominada transformada Hilbert-Huang (*Hilbert-Huang transform* – HHT) [12, 13, 14, 15, 16], visando uma melhor separação entre o sinal de interesse e as mencionadas interferências.

Os algoritmos utilizados atualmente para essa finalidade se baseiam na transformada de Fourier de tempo curto (*short time Fourier transform* – STFT) [17, 18] e na transformada wavelet (*wavelet transform* – WT) [19]. Apesar de bem-sucedidas, a aplicação dessas duas técnicas de análise espectral requer a compreensão de suas respectivas limitações. No caso da STFT, a escolha do tamanho da janela temporal deve ser compatível com o conteúdo espectral específico do sinal analisado, que, a priori, é desconhecido. No caso da WT, a escolha de uma função-base fixa afeta diretamente a efetividade da identificação dos elementos transientes ocultos do sinal dinâmico analisado, por não se adaptar necessariamente às suas variações [20, 21]. Essas limitações dos métodos tradicionais de análise se tornam particularmente evidentes quando aplicados a sinais

experimentais de SONAR passivo, sujeitos que são a variações de velocidade, ao ruído ambiental e à ocorrência de múltiplos sinais na área sob vigilância.

A utilização da HHT no presente trabalho de pesquisa se apresenta como uma proposta alternativa a essas duas técnicas, por ser um método de análise TF cuja base de expansão é adaptativa, sendo obtida do próprio sinal analisado, e, portanto, uma opção mais adequada para a análise de sinais não-estacionários e sistemas não-lineares, tais como os de SONAR passivo. Desse modo, espera-se obter uma ferramenta de análise e caracterização espectral baseada na HHT que permita tornar mais precisos e eficientes os algoritmos de detecção e classificação desses sinais.

Uma das técnicas importantes de análise TF de sinais de SONAR passivo, tradicionalmente utilizadas em aplicações militares, é conhecida como Detecção de Modulação de Envoltória em Ruído (*Detection of Envelope Modulation on Noise* – DEMON), baseada na STFT. Como resultado da aplicação dessa técnica, são obtidas informações relevantes sobre características da embarcação (velocidade e número de pás do hélice) e sobre a sua dinâmica (variação da velocidade, por exemplo), que estão contidas nos componentes de frequência desses sinais. No presente trabalho, é proposto um método alternativo em que a STFT é substituída pela HHT na análise TF de sinais de SONAR passivo realizada pela DEMON tradicional. Adotando-se uma nova abordagem, esse método passará a ser utilizado conjuntamente à DEMON tradicional, fornecendo informações complementares e mais detalhadas ao operador SONAR, sobre aspectos estáticos da assinatura espectral e sobre o comportamento dinâmico das embarcações, os quais não são detectados pela DEMON padrão.

A literatura técnica científica vem relatando várias aplicações da HHT com resultados animadores na solução de problemas em sistemas dinâmicos não-lineares e sinais não-estacionários. Em [20], é apresentada uma técnica de monitoramento do estado de operação de máquinas baseada na transformada Hilbert-Huang (*Hilbert-Huang transform* – HHT), aplicada à análise de sinais vibratórios transientes produzidos em sistemas de máquinas rotativas e motores elétricos. Em [22, 23, 24], o método é usado para a obtenção de diagnóstico de falhas potenciais em máquinas industriais. No artigo [25], constatando a natureza não-linear e não-estacionária do vento, os autores propõem um método de previsão da sua velocidade baseado na decomposição empírica em modos (*empirical mode decomposition* – EMD), com aplicação em sistemas de geração eólicos. A avaliação de desempenho deste método mostra que ele supera os demais tradicionalmente utilizados, no que se refere à precisão e complexidade computacional. Outros métodos baseados em variantes da EMD são propostos em [26, 27] para a previsão da velocidade do vento em parques eólicos. Também são encontradas aplicações da HHT na previsão da radiação solar diária em sistemas fotovoltaicos inteligentes [28, 29, 30], em sistemas de imagens médicas rápidos e eficientes [31, 32, 33], no processamento de sinais acústicos [34, 35] e de voz [36, 37, 38, 39].

Embora vários exemplos de aplicações mostrem que a HHT é um método eficiente de análise TF de sistemas não-lineares e sinais não-estacionários, ela apresenta, no entanto, algumas limitações, que são a mixagem de modos (*mode mixing* – MM) [16] e a sensibilidade ao ruído incidente, sendo esse último agravado nos casos em que o sinal-alvo e o ruído ocupam a mesma banda de frequência, como tipicamente acontece no caso de sinais de SONAR passivo. Em

situações como essa, a separação entre os componentes de interesse e o ruído, realizada na decomposição EMD do sinal ruidoso analisado, pode se tornar complexa.

Considerando a proposta deste trabalho, de implementação de uma ferramenta de análise TF de sinais de SONAR passivo baseada na HHT, para utilização conjunta com a análise DEMON padrão, foi adotada uma estratégia de redução de ruído para a mitigação desse grave problema da EMD, garantindo, assim, a precisão e eficiência necessárias para os algoritmos de detecção e classificação desses sinais. A estratégia adotada é baseada em um sistema inteligente de classificação e na filtragem *wavelet* com limiar (*wavelet denoising threshold* – WTD), que permitem obter uma melhor separação entre os componentes de interesse e o ruído incidente e, consequentemente, o aumento da SNR.

Os sistemas inteligentes de classificação (*intelligent classification system* – ICS) são modelos matemáticos, em geral não-lineares, que apresentam capacidade de generalização (uma vez treinadas, suas respostas se tornam insensíveis a pequenas variações nas suas entradas), adaptação (aprendizagem de novos conhecimentos) e robustez a dados ruidosos [40]. Geralmente são aplicados a problemas em que o alvo é o reconhecimento e identificação de padrões, para posterior separação em classes de interesse [41, 42]. São vários os exemplos de aplicações dos ICS nas áreas de reconhecimento facial [43, 44, 45], controle de navegação autônoma de veículos [46, 47, 48], autenticação de usuário [49, 50, 51], identificação de alvos militares [52, 53, 54], processamento de sinais acústicos submarinos (*underwater acoustic signal processing* – UASP) [55, 56, 57] e predição no mercado financeiro [58, 59, 60].

O sistema classificador inteligente explorado neste trabalho se baseou na avaliação e comparação de desempenho de dois modelos clássicos de classificação binária: a análise discriminante de Fisher (*Fisher Discriminant Analysis* – FDA) [61, 62] e a máquina de vetores-suporte (*Support Vector Machine* – SVM) [63, 64]. Esses dois modelos foram escolhidos em razão do problema de classificação binária que surge na decomposição EMD do sinal de SONAR passivo analisado, qual seja, o de distinguir os componentes espectrais de interesse (classe positiva), daqueles relativos ao ruído incidente. De forma resumida, o ICS realiza a separação entre os componentes de interesse, que são selecionados e tratados pela WTD para redução de ruído, e os componentes de ruído, que são descartados. A classificação é realizada com base em atributos extraídos dos próprios componentes espectrais produzidos pela EMD.

1.2 Objetivos

Este trabalho tem como objetivo principal propor uma nova forma de representação da informação acústica de interesse em sistemas de SONAR passivo, baseada na HHT.

Os objetivos específicos do trabalho são:

- Modificação da ferramenta DEMON, tradicionalmente utilizada na análise e classificação de sinais de SONAR passivo, pela substituição do método de decomposição espectral baseado na STFT pelo método proposto baseado na HHT;
- Avaliação de desempenho de algumas variações da HHT, aplicadas a sinais simulados e

experimentais de SONAR passivo, visando a escolha daquela que se mostrar mais resiliente com relação aos dois principais problemas associados a esse método, quais sejam, a mixagem de modos (MM) e a sensibilidade ao ruído;

- Investigação sobre os principais mecanismos de atuação do ruído incidente em sinais experimentais de SONAR passivo e sobre algumas técnicas baseadas na WTD, usualmente utilizadas para sua redução. O objetivo é definir a estratégia de redução de ruído a ser adotada no sistema proposto;
- Apresentação e avaliação de desempenho do Método de Estimação da Decomposição Empírica em Modos com Remoção Inteligente de Funções de Modo Intrínseco Ruidosas (*EMD Estimation Method with Intelligent Removal of Noisy IMFs* – EMD-IRNI), sistema inteligente para análise TF de sinais de SONAR passivo com redução de ruído, proposto no presente trabalho de doutorado.

1.3 Contribuições da Tese

Este trabalho visa contribuir com o desenvolvimento do EMD-IRNI, método inteligente de análise TF de sinais de SONAR passivo com redução de ruído, a ser disponibilizado como ferramenta alternativa à análise DEMON padrão, para o grupo de parceiros formado pela Universidade Federal do Rio de Janeiro (COPPE/UFRJ), Instituto de Pesquisas da Marinha (IPqM) e Universidade Federal da Bahia (UFBA). Além de possibilitar uma melhor representação dos sinais de SONAR passivo e, conseqüentemente, tornar mais preciso e eficiente o processo de análise e classificação desses sinais, esta tese também tem como contribuição um método de ajuste do limiar de filtragem wavelet Bark com limiar (BWTD, na Seção 3.5.1), que é utilizada no sistema proposto para a redução de ruído dos componentes espectrais de interesse obtidos na decomposição EMD dos sinais analisados.

1.4 Organização do Documento

O texto está organizado da forma descrita a seguir. No Capítulo 2, é apresentada a fundamentação teórica da pesquisa, em que são tratados os principais aspectos relacionados ao sistema de SONAR passivo e ao método proposto EMD-IRNI. No Capítulo 3, apresentamos o método adotado para a obtenção dos resultados e os sinais experimentais e simulados de SONAR passivo utilizados na realização da pesquisa. No Capítulo 4, são apresentados e discutidos os resultados experimentais obtidos e, por fim, no Capítulo 5, são apresentadas as conclusões e as perspectivas de trabalhos futuros. Encerrando o texto, após a citação das referências bibliográficas há três apêndices, sendo que um deles lista os trabalhos publicados no decorrer da pesquisa (Apêndice A), e outros dois fornecem detalhes sobre o sistema proposto EMD-IRNI (Apêndice B) e sobre a construção do padrão-ouro usado no treinamento e validação do classificador integrante desse sistema (Apêndice C).

2 Revisão da literatura

Este capítulo descreve os principais conceitos e técnicas que dão suporte teórico ao presente trabalho. Inicialmente, é apresentada uma breve introdução ao sistema de SONAR passivo, mostrando suas principais características, com ênfase no ruído ambiental, fonte dos problemas mais relevantes enfrentados na análise do sinal de SONAR. Também são explicados a estrutura e o funcionamento da ferramenta DEMON, tradicionalmente utilizada na análise TF desse sinal. Como parte essencial, é apresentado o método transformada Hilbert-Huang com decomposição empírica em modos (*Hilbert-Huang transform with empirical mode decomposition* – HHT-EMD), em que se baseia o sistema proposto EMD-IRNI. Em seguida, são apresentados, de forma resumida, os principais aspectos do método de redução de ruído utilizado, baseado na transformada wavelet Bark. Por fim, são apresentados os modelos de classificação binária e os atributos que foram investigados para a implementação do classificador de IMFs, parte integrante do sistema proposto.

2.1 Sistemas de SONAR Passivo

O SONAR é um sistema empregado na detecção e processamento de sinais acústicos submarinos (*underwater acoustic signal* – UAS), podendo ser utilizado tanto para fins civis quanto militares. No primeiro caso, o SONAR pode ser usado para o monitoramento do ambiente e da fauna submarinos usando técnicas de imageamento [65, 66, 67], exploração de petróleo e gás [68, 69, 70], e detecção de danos em estruturas submarinas [71, 72, 73, 74]. Os sistemas de SONAR podem ser classificados em dois tipos: ativos e passivos.


O SONAR ativo tem como principal característica a emissão de um pulso sonoro [11], que, ao ser refletido em um alvo, retornará à fonte de origem, permitindo, assim, a detecção e localização desse alvo. A vantagem do sistema ativo é a de se saber que tipo de sinal está sendo transmitido, enquanto sua desvantagem é a exposição do transmissor em relação ao alvo, já que o primeiro está emitindo um sinal. Exemplos de aplicações do SONAR ativo são a navegação autônoma, a comunicação e localização submarinas [75, 76, 77].

No caso do SONAR passivo, é realizada a detecção e estimação do som gerado pelo próprio alvo, evitando, portanto, a exposição da localização do receptor [78]. Esse sistema é essencial na tecnologia de defesa, sendo normalmente utilizado pelos submarinos [1, 11], em que a invisibilidade e camuflagem são fatores estratégicos. Em situações que o submarino esteja sendo atacado, o SONAR ativo pode ser usado como um último recurso, para se obter uma melhor estimativa da localização de um alvo. O SONAR passivo também tem aplicações civis, tais como o monitoramento da vida marinha [2, 3, 79, 80] e a exploração do meio subaquático por robôs [81, 82, 83].

Para fins militares, os sistemas de SONAR passivo são essenciais em submarinos, tendo como principais finalidades detectar, classificar e localizar embarcações (também referidas como “contatos”) em um ambiente subaquático, evitando sua própria detecção por outros [84]. O

SONAR passivo explora o fato de que as embarcações alvo se comportam como uma fonte emissora de sinais acústicos, que se propagam pelo ambiente subaquático e eventualmente chegam ao receptor do sistema de SONAR (conjunto de hidrofones). A Figura 1a ilustra um cenário hipotético em que um submarino rastreia dois contatos, usando SONAR passivo. Nesse caso, é utilizado um arranjo cilíndrico de hidrofones (*Cylindrical Hydrophone Array* - CHA), mostrado na Figura 1b. Nessa configuração, os sensores estão dispostos verticalmente (*staves*) e realizam uma aquisição omnidirecional, de acordo com os ângulos de azimuth θ e de elevação φ . O arranjo cilíndrico é utilizado para identificar a direção de chegada do sinal proveniente da fonte sonora de interesse, permitindo ao submarino saber a direção aproximada do contato [1].

Figura 1 – Cenário típico de rastreamento de dois contatos por um sistema de SONAR passivo de um submarino: (a) Cenário (adaptação de [78]) e (b) Arranjo cilíndrico de hidrofones utilizado (Fonte: [1]) .



2.1.1 Ruído acústico submarino

Um dos problemas associados à detecção de uma fonte acústica submarina por um sistema de SONAR passivo é que, em condições reais, o sinal de interesse normalmente está contaminado por diversas fontes de ruído acústico, que podem ser classificadas em duas categorias principais: ruído irradiado por embarcações [1, 85, 86] e ruído ambiente [1, 87, 88]. Além do ruído ambiental, outros alvos presentes num dado cenário podem interferir no processo de detecção e classificação de um contato, sendo necessária a utilização de técnicas de separação dos sinais de interesse [1]. A seguir, são apresentadas as principais características de alguns tipos de ruído acústico submarino:

- **Ruído Irradiado**

O ruído irradiado é proveniente de fontes artificiais, por exemplo, submarinos, navios e plataformas para extração de petróleo. Os principais ruídos irradiados por uma embarcação são o ruído de máquinas, o ruído do hélice e o ruído hidrodinâmico [89, 90, 91].

O ruído de máquinas é originado, em grande parte, pelo sistema de propulsão do navio, que vibra em determinadas frequências, vibrações essas que se propagam pela estrutura da embarcação, formando uma assinatura espectral específica desta embarcação [1, 89, 92].

O ruído do hélice tem origem no processo de cavitação produzido pelo movimento giratório do hélice [89, 93, 94]. Como mostra a Figura 2a, quando o hélice começa a operar, o líquido ao seu redor é agitado, produzindo regiões de alta pressão (parte posterior da pá do hélice) e regiões de baixa pressão (parte anterior do hélice), com consequente formação de bolhas de ar. Quando são atingidas pelo fluxo da água ou pelo próprio hélice, essas bolhas explodem e implodem, gerando um ruído característico [1, 95, 93].


A Figura 2b [78] mostra o espectro de potência típico do ruído irradiado por uma embarcação, que pode ser visto como a superposição de um espectro de banda larga contínuo e um espectro de banda estreita formado por componentes espectrais em frequências discretas abaixo de 1 kHz, produzidos pelos elementos de propulsão (máquinas, turbinas, compressores e bombas) [84]. O ruído banda larga é gerado pelo processo de cavitação, a partir de explosões aleatórias causadas pelo colapso das bolhas de ar, e possui banda de frequência entre 10 Hz e 20 kHz e é modulado em amplitude por uma envoltória com frequência igual à de rotação do hélice [78, 11, 96]. Alguns autores [97, 98, 99] costumam incluir o ruído de cavitação na classe de sinais denominados “ciclo-estacionários”, que são aleatórios por natureza, mas exibem periodicidade em suas estatísticas. Esses pesquisadores se baseiam no fato de a cavitação ser um processo aleatório (banda larga) que apresenta padrões periódicos associados à rotação do hélice.

O ruído hidrodinâmico é produzido pelo fluxo da água sobre o casco do navio em movimento [89]. As variações de pressão associadas a este fluxo são irradiadas a uma certa distância, podendo ser usadas na identificação de alguns tipos de navio.

Figura 2 – Ilustração do ruído irradiado por embarcações: (a) Formação de bolhas de ar no processo de cavitação (Fonte: [11]) e (b) Espectro de potência (Fonte: [78]).



(a)




(b)

- **Ruído Ambiental**

Como o próprio nome sugere, o ruído ambiental é originado por fontes naturais presentes no ambiente no qual o sistema SONAR está localizado, dentre as quais se destacam o ruído biológico, o ruído sísmico, o ruído estado do mar e o ruído da chuva [89].

O ruído biológico é gerado por animais marinhos, incluindo mamíferos, invertebrados e peixes, que utilizam sinais sonoros com frequência específica (10 Hz - 200 kHz) para se comunicar [100, 101, 102, 103, 104]. O ruído sísmico está relacionado às atividades vulcânicas e a terremotos e dominam a banda de frequência abaixo de 1 Hz [105, 106, 107]. O ruído estado do mar combina os efeitos das ondas e do vento que incide na superfície do oceano e é usualmente classificado em sete níveis, associados à altura das ondas. A Figura 3a mostra a relação entre a intensidade e a frequência do ruído estado do mar para vários níveis de onda [78, 108, 109], indicando um comportamento tipicamente passa-baixa. Finalmente, o ruído da chuva é gerado pelo impacto da chuva sobre a superfície do oceano, que é seguido por oscilações provocadas na superfície e pelo ar que é arrastado para baixo da superfície. É classificado em quatro níveis, sendo cada nível associado a uma taxa de precipitação. A Figura 3b mostra o comportamento passa-faixa existente entre a intensidade do ruído da chuva em função da frequência, para vários níveis de chuva [78].

Figura 3 – Espectros de amplitude¹ referentes a fontes típicas de ruído acústico ambiental: (a) estado do mar e (b) chuva (gráficos implementados com base nos dados de [84])



2.1.2 Análise DEMON padrão

Uma técnica de processamento de sinais fundamental em sistemas de SONAR passivo é a DEMON [110, 111, 112, 113, 114, 115], ferramenta de análise espectral em banda estreita, tradicionalmente utilizada para extrair informações do ruído de cavitação gerado pelo hélice de embarcações [93, 94, 110, 116].

A partir da análise espectral do ruído de cavitação, alguns parâmetros da embarcação podem ser extraídos, tais como o número de pás do hélice, que é relacionado ao número de harmônicos no domínio da frequência, o número de eixos e sua velocidade de rotação, que geralmente é associada ao primeiro harmônico do espectro DEMON [78, 110, 117]. Essas


¹ A resposta de um hidrofone é expressa em dB re 1 μ Pa, que representa o número de decibels relativos à tensão de 1 volt, produzida pela aplicação de uma pressão acústica de 1 microPascal (1 μ Pa) sobre o transdutor [78].

informações funcionam como uma assinatura espectral da embarcação, sendo utilizadas na detecção, localização e classificação dos alvos de interesse.

Além disso, a análise do espectro DEMON geralmente fornece importantes informações sobre eventos dinâmicos associados à embarcação, tais como a variação de velocidade ou a aproximação de outras embarcações [1, 114, 118].

Apesar de serem considerados estacionários (ou “ciclo-estacionários”) em sua origem, ao passar por diversas transformações no ambiente marinho onde se propagam, os sinais acústicos gerados pelas embarcações se tornam não-estacionários [1, 119, 120]. Ainda assim, podem ser tratados como localmente estacionários, pela aplicação da STFT [1]. O diagrama de blocos da análise DEMON padrão é apresentado na Figura 4 e detalhado a seguir [111, 121, 122]:

Figura 4 – Diagrama de blocos da análise DEMON.



- Após a seleção de uma determinada marcação (direção), o sinal de entrada adquirido $s[n]$ passa por uma etapa de pré-processamento, na qual ele é inicialmente limitado por um filtro passa-faixa a uma banda de frequência $[1 - 2]$ kHz, para se selecionar a banda do ruído de cavitação [1, 121];
- Ainda na etapa de pré-processamento, o sinal é demodulado, para a obtenção das informações sobre a propulsão da embarcação, contidas na envoltória do ruído de cavitação. Como a frequência de amostragem F_s do sinal (neste trabalho, igual a 31, 250 kHz ou 52, 734 kHz, a depender do conjunto de sinais analisado) é muito elevada, quando comparada à banda de propulsão, são realizadas sucessivamente duas reamostragens em frequência, por um fator de 25 cada uma delas [1, 121];
- A seguir, a STFT é aplicada ao sinal pré-processado $x[n]$, obtendo-se a representação $X(f, i)$ deste sinal no domínio da frequência. O método de estimação utilizado é o periodograma modificado de Welch [123], com uma janela de Hanning $w[n]$ de largura igual a $N_s = 1024$ amostras e fator de sobreposição entre janelas adjacentes (*overlap*) fixado em $0,976^2$ [1, 124]. A expressão analítica de $X(f, i)$, transformada de Fourier em tempo discreto (*discrete time Fourier transform* – DTFT) de $x[n]$ no intervalo da i -ésima janela, é dada pela Equação (2.1), com a frequência contínua f expressa em Hz, $j = \sqrt{-1}$ e assumindo-se um fator de sobreposição unitário [111]:

$$X(f, i) = \left| \frac{1}{N_s} \sum_{n=0}^{N_s-1} x[n] w[n - iN_s] e^{\frac{-j\pi n f}{F_s}} \right| \quad (2.1)$$

² Correspondente a 999 amostras, no caso de $F_s = 31, 250$ kHz e 982 amostras, no caso de $F_s = 52, 734$ kHz.

- Em seguida, é realizada uma filtragem TPSW (*Two-Pass Split Window*) no domínio da frequência (bloco TPSW-F) [125, 126], para estimar e remover o ruído de fundo superposto ao sinal de interesse, obtendo-se, assim, o espectro de frequência $X_F(f)$ do sinal demodulado com ruído de fundo reduzido;
- No bloco NORMALIZA, é obtido $\bar{X}_F(f)$, correspondente à média dos trechos de $X_F(f)$ relativos aos diversos intervalos de $x[n]$, que foram definidos pela janela temporal deslizante $w[n]$ durante a STFT. Também no bloco NORMALIZA, é realizada uma normalização de $\bar{X}_F(f)$, para equalizar os picos dos componentes espectrais. Obtém-se, então, a densidade espectral de potência (*power spectral density* – PSD) média normalizada $\bar{P}(f)$, como mostra a Equação (2.2) [111, 113]:

$$\bar{P}(f) = 20 \log_{10} \left(\frac{\bar{X}_F(f)}{\frac{1}{N_s} \sum_{f=0}^{F_s/2} \bar{X}_F(f)} \right) \quad (2.2)$$

- Finalmente, é obtida a representação gráfica do mapeamento espectral TF realizado pela STFT, que consiste no espectrograma de $X_F(f)$ e na PSD média normalizada $\bar{P}(f)$. Nessa última representação, geralmente é indicado o nível médio de ruído de fundo (NMR), definido a seguir, com base na Equação (2.2):

$$\text{NMR} = \frac{1}{N_s} \sum_{f=0}^{F_s/2} \bar{P}_q(f) \quad (2.3)$$

em que:

$$\bar{P}_q(f) = \begin{cases} \bar{P}(f - \Delta), & \text{caso } F_q - \Delta < f \leq F_q + \Delta \\ \bar{P}(f), & \text{caso contrário,} \end{cases}$$

F_q é a frequência do q -ésimo componente espectral ($q = 1, \dots, N_h$), N_h é o número total de componentes espectrais detectados pela DEMON e Δ é o desvio de frequência contínua em torno de cada F_q , definindo a faixa em que os componentes de frequência são eliminados para o cálculo do valor NMR. O valor de Δ é fixado empiricamente.


2.2 A Decomposição Empírica em Modos e a Transformada Hilbert-Huang

Esta seção descreve os principais aspectos teóricos relacionados à HHT-EMD (transformada Hilbert-Huang com decomposição empírica em modos), em que se baseia a proposta do presente trabalho.

Embora a EMD obtenha representações dos sinais originais no domínio do tempo, a partir de um conjunto de componentes oscilatórios (conhecidos como IMFs), ela também pode ser usada no contexto da HHT, para obter um mapeamento da informação alvo no domínio da frequência. Como é ilustrado na Figura 5 para um sinal experimental de voz [127] $x(t)$, a estimativa da HHT compreende as seguintes etapas:

- (i) A EMD é realizada para decompor o sinal $x(t)$ em um conjunto de componentes ortogonais de média zero, chamadas funções de modo intrínseco (*intrinsic mode functions* – IMFs). As IMFs formam a base de expansão de $x(t)$, obtida adaptativamente a partir do próprio sinal.
- (ii) A transformada de Hilbert (*Hilbert transform* – HT) é aplicada a cada IMF, para a estimação da amplitude instantânea (*instantaneous amplitude* – IA) e frequência instantânea (*instantaneous frequency* – IF).
- (iii) O espectro de Hilbert (*Hilbert Spectrum* – HS) é construído a partir do conjunto de IAs e IFs, preservando a localização temporal dos componentes de frequência.

Figura 5 – Diagrama de blocos da transformada Hilbert-Huang (HHT).



2.2.1 Representação Tempo-Frequência

A representação TF de um sinal fornece informações sobre como o seu conteúdo espectral evolui com o tempo, sendo, portanto, uma ferramenta importante para analisar e interpretar sinais não-estacionários. Assim sendo, existe uma variedade de métodos propostos para se obter, simultaneamente, a densidade de potência em função do tempo e da frequência [128, 129, 130].

Uma condição mais adequada para representar sistemas não-lineares e sinais não-estacionários é ter uma base adaptativa, ou seja, definida a partir dos próprios dados, uma abordagem bem diferente do paradigma matemático tradicionalmente estabelecido para a análise de dados, em que se utiliza uma base fixa e pré-determinada. Apesar de desafiantes, novos métodos para examinar dados do mundo real (geralmente relativos a sinais não-estacionários e sistemas não-lineares) têm sido propostos, entre eles, a HHT-EMD [13].

A representação TF baseada na transformada de Fourier (*Fourier transform* – FT) [131, 132], tradicionalmente usada, pode não ser adequada para análise de sinais aleatórios variantes no tempo expostos a fenômenos não-lineares, tendo em vista que se baseia na superposição linear de funções senoidais (base fixa pré-determinada). Assim sendo, tanto a não-estacionariedade, quanto

a não-linearidade, podem induzir componentes harmônicos espúrios, levando a representações TF sem relação com o fenômeno físico original [13, 133, 134, 135].

Muitos métodos de representação TF têm sido propostos, visando superar essas limitações da FT, incluindo a STFT, a transformada wavelet (WT) [19, 121] e a distribuição de Wigner-Ville (*Wigner-Ville distribution* – WVD) [133].

No caso da STFT, são usadas janelas curtas de tempo para analisar as características espectrais do sinal, assumindo, assim, estacionaridade por partes [18]. No entanto, além de sofrer dos mesmos problemas que a FT, dentro da janela de análise (pois utiliza a mesma largura de janela em todo o intervalo de duração do sinal), a STFT fornece uma resolução TF constante para toda a banda de frequência. Portanto, a STFT apresenta importantes limitações na representação de sinais não-estacionários [136, 137].

Ao contrário da STFT, a WT pode ser usada na análise multiresolução de um sinal, utilizando operações de dilatação e translação da função base. A WT extrai características TF de um sinal em altas e em baixas frequências [136]. No primeiro caso, atinge uma alta resolução temporal, mas uma baixa resolução em frequência, enquanto no segundo caso, ocorre o contrário. Essa capacidade adaptativa de análise TF torna a WT um método mais adequado para analisar sinais não-estacionários [136, 138]. Contudo, um dos principais desafios associados à WT é a necessidade de seleção (a priori) da função base wavelet apropriada [133]. Às vezes, esse aspecto limita a aplicação da análise wavelet em situações em que os sinais são desconhecidos, como no caso do SONAR passivo [139].

Outra representação TF amplamente utilizada na análise de sinais não-estacionários é a WVD. Teoricamente, a WVD proporciona uma resolução TF infinita, devido à ausência de uma operação de média em qualquer intervalo finito de tempo [140]. Na prática, o método apresenta como efeito colateral a introdução de grandes termos cruzados entre cada par de componentes do sinal, e entre frequências positivas e negativas, o que torna sua formulação original pouco adequada para a maioria das aplicações [140].

A HHT é um método empírico de análise de sinais cuja base de expansão é adaptativa, de forma a produzir uma representação espectral significativa de sistemas não-lineares e sinais não-estacionários [13]. Diferentemente da análise de Fourier, em que se utiliza uma base fixa (senoidal) na transformação para o domínio da frequência, ao adaptar-se às variações locais do sinal, a HHT leva em conta o comportamento intrínseco do fenômeno natural [141]. O método tem sido aplicado a vários tipos de sinais não-estacionários [30, 142, 143, 144].

A literatura técnica vem relatando o uso da HHT-EMD em diferentes contextos. Em [145], uma técnica de análise de vibração por sinais foi proposta para identificar falhas em rolamento de máquinas elétricas rotativas. Em [146], a EMD foi usada para obter diagnóstico de possíveis falhas em máquinas industriais. Dois métodos foram propostos para a previsão da velocidade do vento em sistemas de geração de energia eólica, um baseado na EMD e em rede de *link* funcional de vetor aleatório (*random vector functional link network*) [147] e o outro, combinando o modelo de floresta aleatória (*random forest model*) com uma variante da EMD [148]. Um preditor de radiação solar diária inovador foi desenvolvido, integrando a EMD e uma rede neural

para melhorar a eficiência de sistemas fotovoltaicos inteligentes [149].

Na área biomédica, a EMD tem sido usada no diagnóstico de hipertensão [150], compressão de dados de eletrocardiograma [151], reconhecimento de emoções [152, 153], telemedicina [154] e, quando associada a uma rede neural convolucional (*convolutional neural network* – CNN) profunda, apresenta bom desempenho em sistemas de imagens médicas rápidos e eficientes [155].

Na análise de séries temporais, a EMD pode ser usada para a previsão precisa dos preços globais de energia [156, 157], na previsão de preços de carbono [158, 159], para prever tendências climáticas, atendendo às necessidades de precisão na produção agrícola [160, 161] e, combinada com uma CNN, para prever e controlar a poluição do ar [162, 163].

A EMD também tem sido aplicada em processamento de sinais acústicos [34, 35] e de voz [39, 164, 165]. O processamento de sinais de várias fontes (*multi-source signal processing*) também tem sido abordado com a EMD, em que os sinais multidimensionais são concatenados, formando um sinal unidimensional para ser decomposto usando a EMD padrão [166].

O método HHT-EMD também tem sido aplicado na área de processamento de sinais acústicos submarinos (UAS) com resultados promissores [35, 167, 168, 169, 170, 171]. Em tais aplicações, geralmente é necessária uma análise TF para caracterizar as informações adequadamente. No ambiente subaquático, que é variante no tempo e sujeito a fenômenos não-lineares [78, 125, 168, 169], fontes de ruídos acústicos naturais ou não naturais podem comprometer a detecção da informação [139]. Nesse ambiente, podem ocorrer diferentes respostas associadas a múltiplos caminhos de propagação e variações nas propriedades físicas da água devido a mudanças em características do meio submarino, tais como temperatura, profundidade e salinidade [172].

Os algoritmos de análise de UAS mais utilizados atualmente são baseados na STFT e WT. Embora essas duas técnicas de análise espectral tenham obtido bons resultados, é importante entender suas limitações [133]. No caso da STFT, é necessário uma janela de tempo com tamanho e formato compatíveis ao conteúdo espectral específico do sinal analisado, que pode ser desconhecido em um primeiro momento [173], a exemplo dos sinais de SONAR passivo. Além disso, a representação TF baseada na STFT exibe uma quantidade notável de energia espectral cruzada, devido à sobreposição de janelas, o que não ocorre com a HHT-EMD, pois é capaz de representar as informações espectrais instantâneas de uma série temporal sem a utilização de janela [174]. No caso da WT, é necessário escolher uma família de funções base adequada, o que afeta diretamente a eficácia da identificação de elementos transitórios ocultos no sinal dinâmico analisado [173]. A aplicação do método HHT-EMD para análise de UAS surge, portanto, como uma alternativa para superar as restrições impostas pela incerteza da resolução TF tanto na STFT, quanto na WT [139, 175].

2.2.2 O algoritmo EMD

A EMD é um método simples adaptativo de decomposição, cuja essência é identificar e extrair empiricamente os modos intrínsecos de oscilação contidos em um sinal e, em conformidade com esses modos, decompor o sinal em um conjunto de componentes de banda limitada (IMFs) com amplitude e frequência variáveis. Uma IMF é definida por duas propriedades [141, 174, 12]:

- Em todo o intervalo de duração dos sinais, o número de extremos (máximos e mínimos) e de cruzamentos com o nível zero são iguais ou diferem, no máximo, em uma unidade.
- Em qualquer ponto, o valor médio entre as envoltórias definidas pelos extremos locais é zero. Ou seja, são sinais simétricos em relação ao nível zero.

Diferentemente dos componentes harmônicos do espectro de Fourier, que possuem amplitude e frequência constantes, as IMFs podem ter amplitude e frequência variantes com o tempo (AM/FM), sendo, portanto, adequadas para representar sinais não-estacionários [13]. É importante notar que o algoritmo EMD decompõe o sinal-alvo em um conjunto finito e completo de componentes: IMFs e um resíduo.

As IMFs são obtidas através de um procedimento iterativo conhecido como “peneiramento” (*sifting*), em que as assimetrias entre as envoltórias superior e inferior do sinal original $x(t)$ são removidas progressivamente [141, 12].

As etapas básicas do algoritmo EMD são apresentadas a seguir:

1. Para a j -ésima iteração ($j = 1, 2, \dots, K$), determinar todos os extremos locais (máximos e mínimos) do sinal iterativo $d_j(t)$. Na primeira iteração: $d_1(t) = x(t)$;
2. Obter as envoltórias máxima ($e_{\max}^{(j)}(t)$) e mínima ($e_{\min}^{(j)}(t)$) de $d_j(t)$, por interpolação com os valores extremos do sinal;
3. Determinar a curva média:

$$m_j(t) = \frac{[e_{\max}^{(j)}(t) + e_{\min}^{(j)}(t)]}{2}, \quad j = 1, 2, \dots, K \quad (2.4)$$

4. Computar o resíduo $d_{j+1}(t)$:

$$d_{j+1}(t) = d_j(t) - m_j(t), \quad j = 1, 2, \dots, K - 1 \quad (2.5)$$

5. Enquanto $d_{j+1}(t)$ não atender às duas propriedades que definem uma IMF (critério de convergência), as etapas (1) a (4) são aplicadas recursivamente a d_j . Este processo de peneiramento continua por K iterações, até que um critério de parada seja satisfeito [141, 12];
6. Na K -ésima iteração, uma vez atendido o critério de parada, $d_j(t)$ se torna a i -ésima IMF $\{c_i(t) = d_K(t)\}$, $i = 1, 2, \dots, N$, que é extraída de $x(t)$, restando, então, o resíduo $r_i(t)$:

$$r_i(t) = x(t) - d_K(t) \quad (2.6)$$

Como $r_i(t)$ contém informação de componentes com uma escala de tempo (período) maior, ele é tratado como um novo dado $x_r(t)$, e o processo de peneiramento descrito acima é repetido. Essas iterações continuam até que o resíduo se torne monotônico ou um número N de IMFs seja pré-fixado para extração. Neste último caso, o resíduo não será necessariamente monotônico, a depender do que restará após a extração das N primeiras IMFs.

Ao final do processo, o sinal original $x(t)$ pode ser representado por N IMFs e um resíduo final $r_N(t)$ [12]:

$$x(t) = \sum_{i=1}^N c_i(t) + r_N(t) \quad (2.7)$$

Para sinais que mostram uma tendência específica, ela pode ser determinada por diferentes métodos de estimativa. Existem várias definições para o termo “tendência” na literatura, dentre as quais se destaca a que considera um “componente aditivo suave contendo as informações sobre mudanças globais de séries temporais” [176]. Uma série temporal pode ser vista como a superposição de dois componentes, a flutuação e a tendência. A estimativa deste último pode fornecer informações valiosas sobre o processo físico associado, tais como os períodos de componentes cíclicos eventualmente presentes nos dados [177].

Nesse sentido, vários métodos de estimação de tendências têm sido propostos, incluindo técnicas baseadas em regressão, abordagem baseada em modelo (*model-based approach*), análise de espectro singular (*singular spectrum analysis*) e métodos baseados em wavelets [176]. Recentemente, considerando o problema de estimativa de tendências (*trend estimation problem*) na EMD, foi proposta a filtragem de tendências [177]. Neste método, a tendência é aproximada por IMFs lentas, que são identificadas com base na taxa de cruzamentos por zero. O decréscimo de energia da IMF também é considerado nesta seleção e, eventualmente, o resíduo final é incluído [177].

Para obter uma representação do sinal mais simétrica em relação ao nível médio local, o procedimento de peneiramento deve ser repetido várias vezes durante o processo da EMD. No entanto, caso este processo ultrapasse um limite específico (sobre-decomposição), as variações de amplitude intrínsecas contidas no sinal original podem desaparecer na IMF resultante [13, 178]. Para evitar a decomposição excessiva, o número de iterações do processo de peneiramento deve ser limitado por um critério de parada. Como a EMD é um algoritmo numérico, IMFs irrelevantes podem ser produzidas no processo de decomposição, como consequência de possíveis limitações, tais como a utilização de um método de interpolação não ideal, erros de arredondamento numérico no processo de peneiramento e os critérios de parada escolhidos.

Alguns métodos têm sido propostos para selecionar as IMFs relevantes. Em [179] e [180], dois métodos são apresentados, utilizando como critério de seleção os coeficientes de correlação entre as IMFs e o sinal analisado. Quanto maior esse coeficiente, mais relevante é a IMF, que é selecionada com base na comparação com um limiar pré-fixado. Em [181], é proposto um método baseado em energia, que pode ser visto como uma generalização de técnicas baseadas em correlação. Nesse caso, é selecionado um grupo relevante de IMFs, em vez de grupos individuais, como no caso de métodos baseados em correlação. Existe também um método baseado na teoria da informação, que combina EMD com entropia e informação mútua (*mutual information* – MI), para extrair apenas os modos oscilatórios mais informativos [182]. Finalmente, podemos mencionar o método adaptativo de seleção de IMFs relevantes [183], baseado em aprendizado de máquina.

Existem três critérios de parada clássicos na literatura [13, 141, 184], sendo o teste de convergência de Cauchy [13] o mais utilizado. Basicamente, este método avalia o desvio quadrático normalizado entre os resíduos de duas iterações de peneiramento sucessivas e o compara com um

limiar pré-estabelecido. O peneiramento é encerrado quando o desvio se tornar menor que esse limite. A escolha do critério de parada depende da aplicação e é feita empiricamente [178].

Considerando a estrutura de filtro diádica da EMD [16, 185], o conhecimento prévio da banda de frequência na qual o sinal-alvo está localizado pode ser utilizado como critério de parada. A ideia é evitar a geração de IMFs com componentes fora da banda do sinal-alvo.

A escolha do método de interpolação usado para estimar as envoltórias tem um papel crucial no desempenho da EMD [184]. Em sua versão original, a EMD utiliza o método de interpolação *spline* cúbica natural (*natural cubic spline*) por sua simplicidade e flexibilidade [186].


Em [184], os autores consideram que na interpolação linear e polinomial, há uma tendência de aumento significativo do número de iterações de peneiramento. Isso geralmente leva à decomposição excessiva do sinal, com o consequente espalhamento de seus componentes nas IMFs adjacentes (vazamento de componentes). Em razão do menor erro de interpolação, os métodos de interpolação *spline* são preferidos em relação aos polinomiais, mesmo ao usar polinômios de baixo grau como funções base. A interpolação *spline* também evita o fenômeno de Runge, no qual podem ocorrer oscilações ao se interpolar usando polinômios de alto grau [187, 188].

Vários métodos de interpolação têm sido propostos, levando a versões modificadas da EMD, tais como a EMD baseada em interpolação B-spline (*B-spline interpolation-based EMD*) e a EMD baseada em interpolação cardinal *spline* (*cardinal spline interpolation-based EMD*). Tais abordagens reduzem os artefatos de interpolação e o custo computacional [189]. Funções cúbicas polinomiais e trigonométricas são usadas nesses dois métodos, respectivamente. No primeiro caso, as propriedades locais são melhoradas em relação à EMD original, tornando o método mais adaptativo no processamento de sinais não-estacionários [189].

Um sinal experimental típico de SONAR passivo é mostrado na Figura 6a (domínio do tempo), juntamente com o resultado da análise DEMON aplicada a este sinal: as representações TF (Figura 6b) e de frequência (Figura 6c). No primeiro caso, as regiões em branco e em preto representam, respectivamente, a ausência e o valor máximo do sinal, enquanto a escala de cinza mapeia valores intermediários de potência. A análise dos gráficos fornece a assinatura espectral da embarcação e informações sobre o cenário em que se encontra. Os componentes harmônicos em 146,5 rpm e 293 rpm caracterizam um navio com hélice de duas pás girando a aproximadamente 146,5 rpm. A presença de picos de frequência em 120,1 rpm e 304,7 rpm podem indicar possível interferência de outro alvo ou o ruído próprio da embarcação. Vale ressaltar que os valores de frequência geralmente são dados em rotação/minuto (rpm), pois os componentes espectrais são principalmente associados à rotação do hélice do navio e às máquinas.

O resultado da aplicação da EMD a este sinal é apresentado na Figura 6d, para um conjunto de $N = 9$ IMFs e o resíduo final. À medida que o índice i cresce (de 1 a 9), a i -ésima IMF apresenta oscilações com frequência sucessivamente menores. Isso parece razoável, uma vez que o processo de peneiramento é baseado em sucessivas extrações de componentes de baixa frequência (curva média das envoltórias), até que uma IMF seja obtida, atuando como um rastreador de componentes de alta frequência. Assim sendo, as IMFs de maior frequência são obtidas primeiramente.

Figura 6 – Resultados da análise DEMON e da HHT-EMD de um sinal de SONAR passivo: (a) sinal no domínio do tempo; (b) espectrograma; (c) PSD média normalizada $\bar{P}(f)$; (d) IMFs resultantes da aplicação da EMD; (e) HS e (f) MHS (Fonte: Marinha do Brasil).



2.2.3 Transformada Hilbert-Huang

A transformada de Hilbert (HT) pode ser aplicada para se obter a representação TF das IMFs. A combinação da HT com a EMD é referida na literatura como a transformada de Hilbert-Huang (HHT) [12]. No presente trabalho, essa combinação é referida como HHT-EMD.

Uma vez estimadas as N IMFs $c_i(t)$, $i = 1, 2, \dots, N$ (Equação (2.7)), a amplitude instantânea $a_i(t)$ e a frequência instantânea $f_i(t)$ [190, 191, 192] são estimadas, usando as Equações (2.8), (2.9) and (2.10), em que $z_i(t)$ é a denominada versão analítica (definida pela Equação (2.8)) da i -ésima IMF $c_i(t)$ e $\text{HT}\{\cdot\}$ é o operador transformada de Hilbert [133, 12]:

$$z_i(t) = c_i(t) + j\text{HT}\{c_i(t)\} = a_i(t)e^{j\varphi_i(t)} \quad (2.8)$$

em que $a_i(t) = |z_i(t)|$ e $\varphi_i(t) = \arg\{z_i(t)\}$,

$$\text{HT}\{c_i(t)\} = \int_{-\infty}^{\infty} \frac{c_i(t-\tau)}{\pi\tau} d\tau \quad (2.9)$$

$$f_i(t) = \frac{1}{2\pi} \frac{d}{dt} \varphi_i(t) \quad (2.10)$$

O espectro global de amplitude de Hilbert (HS) $H(\omega, t)$, associado a $x(t)$, é dado pela superposição das contribuições individuais $a_i(t)$ e $f_i(t)$ das N IMFs $c_i(t)$ [133, 12], em que ω é a frequência angular de tempo contínuo:

$$H(\omega, t) = \sum_{i=1}^N a_i(t) \exp\left(j \int_{-\infty}^t \omega_i(\tau) d\tau\right), \quad (2.11)$$

em que $\omega_i(t) = 2\pi f_i(t)$.

A forma discreta do HS é obtida da Equação (2.11) e fornece a representação 3D tempo-frequência-amplitude de um dado sinal $x(t)$ como uma função da frequência discreta k e do tempo discreto n . A Equação (2.12) mostra que o espectro global discreto de Hilbert $H[k, n]$ resulta da superposição dos espectros de Hilbert $H^{(i)}[k, n]$ das N IMFs individuais [133, 174]:

$$H[k, n] = \sum_{i=1}^N H^{(i)}[k, n], \quad n = 1, 2, \dots, N_s; \quad k = 1, 2, \dots, \frac{F_s}{2\Delta f} \quad (2.12)$$

em que N_s , F_s e Δf são o número total de amostras, a frequência de amostragem e a resolução em frequência, respectivamente.

A partir de $H(\omega, t)$, é possível obter o espectro marginal de Hilbert (MHS), representando a amplitude total relativa a cada componente de frequência instantânea $f(t)$, acumulada no intervalo de duração do sinal $[0, T]$ [12]:

$$h_M(\omega) = \int_0^T H(\omega, t) dt, \quad \omega = 2\pi f. \quad (2.13)$$

O MHS pode alternativamente ser expresso na forma discreta:

$$h_M[k] = \sum_{n=1}^{N_s} H[k, n] \quad (2.14)$$

Enquanto o MHS representa, em um índice de frequência k , a energia acumulada ao longo de todo o intervalo de dados, em um sentido probabilístico, o HS corresponde à distribuição TF de amplitude, indicando o exato momento de ocorrência do componente neste índice [12]. Assim sendo, as interpretações do MHS e do espectro de Fourier são bastante diferentes. Enquanto neste último a existência de energia no índice de frequência k significa a persistência de um componente senoidal em todo o período $[0, T]$ dos dados, no MHS significa que há uma maior probabilidade deste componente ter aparecido localmente [133, 14].

As Figuras 6e e 6f mostram os resultados da análise HHT do sinal de SONAR passivo da Figura 6a. As representações tempo-frequência (HS) e em frequência (MHS) podem ser vistas na Figura 6e e Figura 6f, respectivamente, de modo análogo àquelas resultantes da análise DEMON aplicada ao mesmo sinal, como mostrado na Figura 6b e Figura 6c, respectivamente. A comparação entre as Figuras 6b e 6e, e entre as Figuras 6c e 6f, mostra que, também no caso do HS e MHS, quatro componentes de frequência significativos estão presentes, com frequências relativamente próximas àquelas dos componentes presentes nas representações TF e em frequência da análise DEMON.

Portanto, também é possível obter informações estáticas do HS e MHS (assinatura espectral da embarcação) e informações dinâmicas (mudanças de velocidade e possíveis interferências de outras embarcações e do ruído próprio) semelhantes às obtidas da análise DEMON. A correspondência entre as representações do HS/MHS e da análise DEMON (espectrograma e PSD média normalizada $\bar{P}(f)$, respectivamente), é usada ao longo deste trabalho para comparar os resultados da análise de sinal realizada com os dois métodos.

2.2.4 Comparação entre HS e STFT

Considerando a correspondência entre as representações TF da HHT-EMD (HS) e da análise DEMON (espectrograma), abordada no final da seção anterior, na presente seção é realizada uma análise comparativa detalhada entre o HS e a STFT.

A análise de um sinal no domínio TF compreende, entre outros aspectos, localizar, detectar e medir eventos experimentais ou sintéticos [13]. Para isso, quanto menores forem as resoluções temporal (Δt) e de frequência (Δf) (onde t e $f = \omega/2\pi$ são as variáveis de tempo contínuo e de frequência contínua, respectivamente), melhor será a caracterização de tais eventos [13, 133]. No caso da STFT, as escolhas de Δt e Δf não são independentes e devem satisfazer o teorema de “Gabor-Heisenberg”, expresso pela relação $\Delta t \Delta f \geq 0,5$ [190, 191]. Portanto, se a janela de tempo escolhida for pequena, para garantir uma boa resolução temporal e estacionariedade localizada, a resolução de frequência se deteriorará (Δf será grande). Por outro lado, o HS não utiliza uma janela de tempo, dado que Δt é igual ao período de amostragem $1/F_s$, e Δf é limitado apenas pelo teorema de Nyquist. Portanto, teoricamente, o HS fornece uma melhor representação TF em relação à STFT [133].

Outro aspecto a ser considerado nesta comparação diz respeito à transformação inversa do sinal original, do domínio TF para o domínio do tempo. Enquanto no HS o erro de reconstrução é insignificante, na STFT o processo de reconstrução pode ser bastante complicado, especialmente quando há sobreposição entre janelas temporais adjacentes [13, 133]. Tal sobreposição pode causar o surgimento de energia espectral cruzada entre janelas adjacentes e consequente dispersão espectral na faixa de alta frequência [133]. Nesse caso, é necessário saber o número de pontos usados na FFT, o tipo e a largura da janela e o tamanho do fator de sobreposição entre janelas (*overlap*). No caso do HS, nenhum parâmetro é necessário para o retorno do sinal ao domínio do tempo, visto que, durante a aplicação da HT, a parte real $\text{Re}[H(\omega, t)]$ (Equação (2.11)) do sinal permanece inalterada e, portanto, pode ser recuperada por filtragem [133]. Por outro lado, o HS não inclui uma quantidade significativa de termos cruzados e, portanto, apresenta uma definição de frequência mais nítida em comparação com a representação TF baseada na STFT [133].

2.2.5 Variações da EMD

Teoricamente, a EMD é uma ferramenta de análise muito eficiente para decompor um sinal multicomponentes em um conjunto de IMFs (componentes contendo um único modo oscilatório) [13]. Mas, na prática, pode apresentar algumas limitações, sendo a mixagem de modos (*mode mixing* – MM) uma das mais graves. Este fenômeno consiste na presença de modos oscilatórios com escalas de tempo muito diferentes, misturados em uma mesma IMF ou um modo oscilatório que se espalha no tempo por diferentes IMFs. O último efeito é normalmente referido como espalhamento modal (*mode splitting* – MDS) [12, 16, 193, 194].

A MM resulta da forma como a EMD gera uma IMF no processo de peneiramento [12]. Em casos de sinais intermitentes, com ruído excessivo ou que possuem componentes de frequência muito próximos, este processo pode falhar [194]. Algumas modificações no algoritmo original da EMD têm sido propostas na literatura, para reduzir o problema da MM [16] e a sensibilidade ao ruído, sendo essa última abordada na Seção 2.2.6.

Dentre os algoritmos variantes, estão os assistidos por distúrbios (*disturbance-assisted*) [195], tais como a decomposição empírica do conjunto em modos (*ensemble empirical mode decomposition* - EEMD), decomposição empírica do conjunto em modos complementar (*complementary ensemble empirical mode decomposition* - CEEMD), decomposição empírica do conjunto em modos completa com ruído adaptativo (*complete ensemble empirical mode decomposition with adaptive noise* - CEEMDAN), decomposição empírica do conjunto em modos completa com ruído adaptativo melhorada (*improved complete ensemble empirical mode decomposition with adaptive noise* - ICEEMDAN), decomposição empírica em modos com sinal-máscara (*empirical mode decomposition with masking-signal* - MS-EMD) e decomposição empírica em modos com fase uniforme (*uniform phase empirical mode decomposition* - UPEMD) [16, 139, 195, 196, 197].

Além dos métodos variantes da EMD, também se destaca a decomposição em modos variacionais (*variational mode decomposition* – VMD) [198] que, diferentemente da EMD e suas variantes, não só possui uma base teórica sólida, mas também uma maior velocidade de convergência e robustez ao ruído [199, 198, 167, 200], tendo praticamente solucionado os problemas de mixagem de modos (MM) e de IMFs não-relevantes existentes na EMD [198, 167]. A VMD

também proporciona uma boa separação tonal, inclusive para componentes de frequência muito próximos [198]. Essa última característica é particularmente interessante em se tratando de sistemas de detecção de sinais de SONAR passivo, tendo em vista a proximidade entre os componentes espectrais harmônicos, geralmente existente nesses sinais. Um resumo da fundamentação teórica da VMD é apresentado no Apêndice B.

Em razão de suas múltiplas vantagens, a VMD tem sido amplamente utilizada na área de análise e processamento de sinais UAS, em pesquisas aprofundadas sobre métodos de extração de características do ruído irradiado por embarcações. Em [201], um método de entropia de dispersão baseado na flutuação da VMD (*VMD-fluctuation-based dispersion entropy*) classifica com sucesso embarcações alvo. Combinando a VMD com a entropia de permutação multi-escala (*multiscale permutation entropy*), é proposto em [202] um método de extração de características do ruído irradiado que permite distinguir diferentes embarcações alvo. Em [203], os autores combinam a VMD com a nova entropia de permutação (*new permutation entropy*) para redução de ruído e extração de características de sinais irradiados.

Esses métodos têm sido empregados em diversas aplicações e geralmente levam a melhores resultados na análise de sinais experimentais quando comparados à EMD original. As características específicas de alguns deles os tornam potencialmente mais adequados para aplicação em sinais acústicos submarinos (UAS) e são brevemente discutidas em [16].

2.2.6 Resiliência ao Ruído

Apesar de se destacar como um método adequado para análise de sinais não-estacionários, a EMD não consegue solucionar casos em que o sinal-alvo e o ruído ocupam a mesma banda de frequência. Nesses casos, a separação entre as IMFs de interesse e as ruidosas pode se tornar impossível [204].

Em aplicações específicas (como SONAR passivo), em que as informações de interesse contidas no sinal ruidoso analisado estão associadas a componentes de frequência senoidais ou de banda estreita, e o ruído geralmente é de banda larga, a EMD pode produzir três tipos de IMFs [190, 205]:

1. IMF-ruído (IMF-R): contendo apenas ruído de banda larga, que pode, portanto, ser descartado;
2. IMF de transição (IMF-T): que contém sinal-alvo e ruído, podendo ser tratada por algum método de redução de ruído adequado;
3. IMF verdadeira: sinal monocomponente (ou aproximadamente monocomponente) banda estreita, associado a uma informação significativa.

As formas mais comuns de lidar com o ruído na estimativa da EMD são: (i) atenuação do ruído usando um estágio de redução de ruído das IMFs e (ii) aplicação de versões modificadas da EMD que são resilientes a ruído aditivo [139, 97].

Dada a sua simplicidade de implementação, métodos de filtragem linear, como a filtragem Wiener [206], têm sido tradicionalmente usados. No entanto, esses métodos não são otimizados para o processamento de sinais provenientes de sistemas não-lineares e não-estacionários, principalmente quando são de banda larga, ocupando a mesma faixa de frequência da banda de ruído, o que às vezes pode ocorrer para UAS [207]. Nesse cenário, métodos de filtragem não-linear, como a filtragem wavelet com limiar (WTD), podem ser aplicados para superar essa limitação [208].

Um dos maiores desafios dos métodos de redução de ruído é preservar os componentes de interesse presentes no sinal ruidoso e eliminar apenas aqueles relacionados ao ruído. Esse problema aumenta quando os componentes de ruído ocupam a mesma banda de frequência do sinal de interesse, a exemplo dos sinais de SONAR passivo [208].

Nesse sentido, o princípio de funcionamento da WTD é baseado na suposição de que, após a decomposição wavelet, a energia total do sinal-alvo é concentrada em apenas alguns coeficientes wavelet de alta amplitude. Ao mesmo tempo, o ruído é mapeado em coeficientes de baixa amplitude [209]. Assim sendo, o processo de redução de ruído da WTD consiste em definir um limiar de comparação para selecionar os coeficientes de interesse (com amplitude superior ao limiar) e eliminar, no caso do limiar rígido (*hard threshold*) ou atenuar, no caso do limiar suave (*soft threshold*), os componentes do ruído (com amplitude menor que o limiar), melhorando a relação sinal-ruído (SNR) do sinal [210].

O principal problema da abordagem wavelet é que seu bom desempenho é altamente dependente da escolha ótima dos parâmetros de funcionamento, quais sejam, a função-base wavelet, o nível de decomposição e o limiar de comparação, que geralmente são de difícil determinação, sendo fixados de forma empírica [211]. Além disso, as funções-base wavelet são fixas, não se adaptando necessariamente às variações do sinal analisado [207]. Nesta pesquisa, foram investigados dois métodos de filtragem WTD: um método clássico, utilizando a transformada wavelet estacionária discreta (*discrete stationary wavelet transform* – SWT) e a filtragem wavelet Bark com limiar (*Bark wavelet threshold denoising* - BWTD), apresentada na Seção 2.3. O primeiro método será referido neste trabalho como WTD-SWT.

Embora estudos recentes mostrem que a HHT-EMD pode ser aplicada com eficiência a UAS, extrair informações precisas de sinais irradiados por navios pode se tornar um desafio devido aos altos níveis de ruído de fundo [199]. Assim sendo, vários métodos têm sido propostos para reduzir a influência do ruído na estimação das IMFs. Em [197], por exemplo, uma nova técnica foi proposta para remoção de ruído em UAS com base na combinação da CEEMDAN, informação mútua (MI), entropia de permutação (PE), e filtragem WTD. Nesse trabalho, as IMF-R são identificadas e removidas, enquanto a WTD é aplicada nas IMF-T. Em [139], a UPEMD é associada à entropia de permutação com reconhecimento de amplitude (*amplitude-aware permutation entropy*) e ao coeficiente de correlação de Pearson (*Pearson correlation coefficient*), para identificar e separar as IMF-T e IMF-R, das IMFs verdadeiras. Um método híbrido de redução de ruído e previsão para UAS foi proposto em [212], combinando a VMD e a entropia de dispersão (*dispersion entropy*) para analisar a complexidade das IMFs.

2.3 Filtragem Wavelet Bark com Limiar

A percepção de tonalidade pelo sistema auditivo humano está relacionada de forma não-linear à frequência do sinal sonoro detectado. Ou seja, a distância entre dois tons na banda de altas frequências é maior do que na banda das baixas, mantendo-se a mesma distância tonal perceptiva entre eles [213].

Apesar desse comportamento não-linear verificado na escala de frequências reais, a percepção tonal é linear na escala Bark de frequências. A Equação (2.15) expressa a relação entre a frequência real (linear) f (em Hz) e a frequência Bark b (em *Bark*) [214], sendo $\text{arc sinh}(\cdot)$ o operador arco seno hiperbólico:

$$b = 6.7 \text{ arc sinh} \left(\frac{f - 20}{600} \right) \quad (2.15)$$

O método de filtragem wavelet Bark com limiar (*Bark wavelet threshold denoising - BWTD*) proposto em [214] se baseia na robustez natural ao ruído do sistema auditivo humano [215]. Ao combinar as características da escala Bark com as da análise wavelet, a BWTD se credencia como um método apropriado para a análise de sinais ruidosos, a exemplo dos sinais de SONAR passivo [216, 217].

A seleção da função wavelet Bark (*Bark wavelet function - BWF*) tem como critério principal a otimização simultânea da análise nos domínios do tempo e da frequência. Isso é obtido pela minimização do produto tempo-banda, com a escolha da wavelet-mãe Gaussiana. A Equação (2.16) define a BWF no domínio Bark [214, 217]:

$$W(b) = e^{-\lambda b^2} \quad (2.16)$$

em que λ é uma constante fixada em $4 \ln 2$, para uma largura de banda referente a 3 dB.

Uma vez definida a banda de frequência linear $|f| \in [f_l, f_u]$ para a análise do sinal em tempo discreto $x[n]$, obtém-se a banda correspondente $|b| \in [b_l, b_u]$ no domínio Bark (Equação (2.15)). Em razão da linearidade da percepção tonal na escala Bark, a banda $[b_l, b_u]$ é dividida em M subbandas Gaussianas igualmente espaçadas, obtendo-se o seguinte conjunto de funções wavelet no domínio Bark [214, 217]:


$$W_m(b) = W(b - b_l - m\Delta b), \quad m = 0, 1, \dots, M - 1 \quad (2.17)$$

em que m é o parâmetro de escala e $\Delta b = (b_u - b_l)/(M - 1)$ é o passo de translação. Substituindo-se as Equações (2.15) e (2.16) na Equação (2.17), obtém-se a wavelet Bark normalizada, como uma função da frequência linear f [214]:

$$W_m(f) = 2^{[-4(6.7 \text{ arc sinh}((f-20)/600) - (b_l + m\Delta b))^2]}, \quad m = 0, 1, \dots, M - 1 \quad (2.18)$$

Na Figura 7, é apresentado um exemplo ilustrativo do espectro de frequência de uma wavelet Bark com $M = 10$ subbandas e banda total definida entre $f_l = 300$ Hz e $f_u = 3400$ Hz.

Figura 7 – Espectro de frequência da wavelet Bark com 10 subbandas.



A seguir, são apresentadas as etapas da BWTD [214], aplicada ao sinal ruidoso $x[n]$ ($n = 0, 1, \dots, N_s - 1$), composto de uma parcela de sinal de interesse e outra de ruído:

- Inicialmente é calculado $X[k]$ ($k = 0, 1, \dots, N_s - 1$), transformada discreta de Fourier (*discrete Fourier transform* - DFT) de $x[n]$;
- Em seguida, é realizada a transformação wavelet Bark, pelo cálculo da sequência $S_m[k] = |W_m[k]| \times |X[k]|$ ($m = 0, 1, \dots, M - 1$), para cada uma das M subbandas. As sequências $S_m[k]$ correspondem aos coeficientes wavelet do sinal de interesse e do ruído incidente, obtidos nas M subbandas, correspondentes às várias escalas de decomposição
- Considerando que as amplitudes dos coeficientes do sinal de interesse são relativamente bem maiores que as do ruído, essas duas classes de coeficientes podem ser separadas utilizando-se um limiar de seleção Thr_m (*hard* ou *soft threshold*) apropriado, escolhido para as diferentes escalas (M subbandas). O ajuste do patamar normalmente é feito de modo empírico, adotando-se algum critério baseado em informações estatísticas extraídas do próprio sinal analisado $x[n]$ [218]. Em [216] e [217], por exemplo, a filtragem BWTD é utilizada para redução de ruído em UAS, sendo empregado um limiar de seleção adaptável, calculado com base no critério SURE (*Stein's Unbiased Risk Estimate*);
- Após a separação, os coeficientes de ruído são eliminados e os coeficientes do sinal de interesse $S_m^{\text{th}}[k]$ são selecionados;

- Em seguida, é realizada a transformação wavelet inversa, pela aplicação da transformada discreta inversa de Fourier (*inverse discrete Fourier transform*) aos coeficientes selecionados $S_m^{\text{th}}[k]$, obtendo-se $s_m^{\text{th}}[n]$, representação no domínio do tempo discreto;
- Finalmente, é realizada a reconstrução do sinal original $x[n]$ com ruído reduzido:

$$x_r[n] = \sum_{m=0}^{M-1} s_m^{\text{th}}[n] \quad (2.19)$$

2.4 Sistemas de Classificação Binária

Um sistema de classificação binária corresponde a um modelo que realiza a escolha entre duas hipóteses: H_1 , normalmente associada à ocorrência do evento de interesse e H_0 , que representa a ocorrência de evento não relevante.

Uma das formas de se implementar um classificador binário é por meio de aprendizagem de máquina, a partir dos dados (experimentais ou simulados) relativos ao processo aleatório (PA) em questão, que são usados na construção de um modelo com regras de decisão. Nesse modelo, o limiar de decisão para a estimação de classes é determinado por várias realizações do PA e pelo conhecimento de um especialista, usado para atribuir os rótulos das classes. Esses rótulos passam a integrar o padrão-ouro (gabarito), usado no treinamento e validação do modelo do classificador.

Na presente pesquisa, foram investigados dois modelos clássicos de classificação binária, baseados em aprendizado de máquina (*machine learning* – ML): FDA e SVM.

Usualmente, o projeto de classificadores abrange três etapas [219, 42]:

- **Treinamento**, em que ocorre a aprendizagem do modelo. Consiste em ajustar os parâmetros internos do modelo com base em um conjunto de exemplos estatisticamente representativo do processo em questão (conjunto de treinamento), visando a ocorrência mínima de erros durante a operação do modelo em condições reais;

Validação, realizada conjuntamente ao treinamento, em que um conjunto distinto de exemplos (conjunto de validação) é aplicado ao modelo treinado. O objetivo dessa etapa é permitir a comparação de vários modelos treinados e seus respectivos hiperparâmetros, visando a escolha daquele que apresentar o melhor desempenho. Também permite evitar o sobre-aprendizado do modelo (*overfitting*);

- **Teste**, em que o modelo treinado e validado é testado com um terceiro conjunto distinto de exemplos (conjunto de teste), visando avaliar sua capacidade de identificar corretamente novos exemplos (generalização).

Nos casos em que se dispõe de poucos dados ou em que assume-se uma boa representação estatística do fenômeno com a base de dados, podemos unificar as etapas de validação e teste [219].

2.4.1 Análise discriminante de Fisher

Também conhecida como Análise Discriminante Linear (*linear discriminant analysis* – LDA), a FDA foi primeiramente proposta por Sir. Ronald Aylmer Fisher em um artigo focalizado em estatística na área de genética [61], se destacando como uma técnica muito utilizada para redução de dimensionalidade em aplicações de ML e classificação de padrões [220].

A ideia básica da LDA consiste em determinar uma direção $\mathbf{W}$ de projeção dos dados em um espaço de dimensionalidade reduzida, de forma a maximizar a separação entre as classes.

Para atingir esse objetivo, a LDA busca maximizar (no espaço projetado) a variância entre-classes (*between-class variance*), definida como a distância entre as médias das diferentes classes, enquanto também tenta minimizar as variâncias intra-classe (*within-class variance*), ou seja, a distância entre a média e as amostras dentro de cada classe. Analiticamente, a LDA é formulada pela Equação (2.20), conhecida como critério de Fisher [220]:

$$\arg \max_{\mathbf{W}} \frac{\mathbf{W}^T \mathbf{S}_B \mathbf{W}}{\mathbf{W}^T \mathbf{S}_W \mathbf{W}} \quad (2.20)$$

em que $\mathbf{S}_B$ e $\mathbf{S}_W$ são as matrizes de dispersão entre-classes e intra-classe, respectivamente, e $\mathbf{W}$ é a matriz de transformação utilizada na projeção do conjunto de dados, sendo obtida pelo cálculo dos autovalores $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_M\}$ e autovetores $\mathbf{V} = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_M\}$ da Equação (2.21):

$$\mathbf{S}_W \mathbf{W} = \lambda \mathbf{S}_B \mathbf{W} \quad (2.21)$$

A LDA é uma das técnicas mais utilizadas em problemas envolvendo redução de dimensionalidade e extração de atributos, tais como no reconhecimento facial [221, 222] e em aplicações na agricultura [223, 224, 225] e na área médica [226]. No entanto, ela apresenta problemas nos casos em que as classes não são linearmente separáveis e quando estão disponíveis poucas amostras de treinamento para cada classe, em comparação à dimensionalidade do espaço [220]. No primeiro caso, a solução é utilizar funções Kernel (Gaussiana, RBF³ ou polinomiais). Quanto ao segundo caso, conhecido como problema do pequeno conjunto de amostras (*small sample size* – SSS), existem propostas utilizando técnicas de regularização [227] e de redução de dimensionalidade [228].

No classificador FDA utilizado na presente pesquisa⁴, o problema do SSS é solucionado opcionalmente por duas variantes da LDA: a análise discriminante linear regularizada (*regularized linear discriminant analysis* – RLDA) e a análise discriminante quadrática (*quadratic discriminant analysis* – QDA).

Métodos lineares, como os baseados na LDA, podem apresentar baixo desempenho quando aplicados a padrões sujeitos a grandes variações, a exemplo dos que são gerados por algoritmos de reconhecimento facial, geralmente resultando em distribuições não-lineares complexas. Nesses casos, uma melhor solução pode ser alcançada usando métodos quadráticos, tais como a QDA, que permite a formação de fronteiras discriminantes complexas entre classes [227, 228]. No

³ função de base radial (*radial basis function* – RBF)

⁴ Implementado pela rotina `fitcdiscr` do MATLAB®2020.

caso da RLDA, uma pequena perturbação é adicionada à matriz de dispersão intra-classe $\mathbf{S}_W$ (Equação (2.20)), utilizando-se um parâmetro de regularização, que precisa ser adequadamente ajustado para não ocorrer degradação de desempenho do método [220, 227].

Uma vez solucionado o problema do SSS, a LDA geralmente apresenta bom desempenho em aplicações envolvendo pequenos conjuntos de dados, como mostram os exemplos a seguir.

Em [221] é proposto o modelo SFTA-LDA-RLO de reconhecimento facial, que utiliza o algoritmo análise de textura fractal baseada em segmentação (*segmentation-based fractal texture-analysis* – SFTA) para extração de atributos, combinado ao classificador oráculo linear aleatório (*random linear oracle* – RLO), para reconhecimento térmico de imagens, e a LDA, para redução de dimensionalidade. Os resultados experimentais mostram que o modelo proposto alcançou uma acurácia de reconhecimento de 94,12%, utilizando um conjunto com 160 imagens de treinamento e 40 imagens de teste. Este resultado é um pouco melhor que o apresentado em [229] em que, utilizando uma abordagem baseada na combinação de *Harr wavelet*, análise de componentes principais (*principal component analysis* – PCA) e classificador de distância mínima (*minimum distance classifier*), obteve-se uma acurácia de 94,11%, com o mesmo conjunto de dados.

Em [223] é proposto um sistema de identificação e classificação de plantas a partir de imagens 2D que utiliza a LDA. Os resultados experimentais apresentam acurácia de até 90% com a utilização de apenas 5 imagens para treinamento, superando abordagens baseadas em PCA e LDA unidimensionais, com acurácias de 68,9% e 75%, respectivamente.

Por fim, é proposto em [226], um método eficiente e computacionalmente rápido de seleção e classificação de genes baseado na LDA, para ser utilizado na análise estatística em diagnóstico preventivo de câncer. O método apresenta uma acurácia de 97,3% no diagnóstico de câncer pulmonar, utilizando 38 amostras para treinamento e 34 amostras para treino, superando as de outras abordagens, tais como *C4.5 decision tree* (93%), *bagging decision tree* (88%) e *boosting decision tree* (81%) [230, 231].

2.4.2 Máquina de vetores-suporte

As máquinas de vetores-suporte (SVMs) são técnicas de ML supervisionado amplamente utilizadas, que se destacam pela boa acurácia de classificação, relativa facilidade de uso e fundamentação teórica rigorosa, além de apresentarem grande robustez na resolução de problemas práticos de reconhecimento de padrões e regressão [219, 63]. São baseadas em conceitos da Teoria do Aprendizado Estatístico (*statistical learning theory* – TAE), desenvolvida por Vapnik [232], que estabelece condições matemáticas para a escolha de classificadores com bom desempenho de generalização, ou seja, com capacidade de prever corretamente a classe de novos exemplos (validação), a partir do modelo desenvolvido no treinamento [63].

A SVM é um classificador que pode efetivamente solucionar problemas de classificação não-linear, bem como aqueles em que não se dispõe de um grande conjunto de dados para treinamento e teste.

Originalmente desenvolvida para classificação binária, no caso de padrões linearmente separáveis, o objetivo da SVM é a construção de um hiperplano H_0 como superfície de decisão,


de tal forma que a distância entre os exemplos das classes seja maximizada. Tendo em vista que, em situações reais, os padrões não são linearmente separáveis, é realizado um mapeamento não-linear desses padrões para um espaço de maior dimensão, denominado espaço de características (*feature space*) [233], no qual o conjunto mapeado é linearmente separável [63]. Como é explicado a seguir, esse mapeamento é realizado de forma implícita, utilizando uma função kernel $\Phi(\cdot)$ que atende às condições estabelecidas pelo teorema de Mercer [234, 235]. As funções kernel mais utilizadas em SVM são as polinomiais, a Gaussiana (ou redes RBF) e as sigmoidais [219, 63].

Considere-se um conjunto de treinamento com M_d exemplos (amostras) $x_i \in X$ ($i = 1, 2, \dots, M_d$) e seus respectivos rótulos de classe $y_i \in Y$, em que X é o espaço de amostras e $Y = \{-1, +1\}$. Esse conjunto é dito linearmente separável caso seja possível separar as amostras nas classes $+1$ e -1 , utilizando o hiperplano H_0 (Equação (2.22)) como superfície de decisão [219, 63].

$$H_0 : f(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + b = 0 \quad (2.22)$$

em que $\mathbf{w}^T \cdot \mathbf{x}$ é o produto interno entre o vetor de pesos $\mathbf{w}$ e o vetor de amostras $\mathbf{x} = \{x_i\}$, enquanto b é um fator de viés (*bias*). Tem-se, portanto, como regra de decisão para a separação, a seguinte atribuição: se $f(\mathbf{x}) \geq 0$, a amostra $\mathbf{x}$ é designada à classe cujo rótulo é $+1$; caso contrário, atribui-se o rótulo -1 [219, 63].

Figura 8 – Ilustração do hiperplano ótimo de decisão H_0 do classificador SVM. São indicados os vetores-suporte e as margens de separação (adaptado de [41]).



A Figura 8 apresenta uma interpretação geométrica da construção do hiperplano ótimo H_0 . Em suma, o processo consiste em maximizar a margem de separação d (distância Euclidiana) entre H_0 e os exemplos mais próximos pertencentes às duas classes (vetores de suporte), impondo-se a condição de inexistência de exemplos situados entre H_1 e H_2 , representações canônicas positiva e negativa de H_0 , respectivamente. Este é um problema clássico de otimização, solucionável pela programação quadrática (*quadratic programming problem* – QPP) [219, 236].

No entanto, a QPP é computacionalmente custosa, o que torna as SVMs padrões inadequadas para aplicação em grandes conjuntos de dados. Nesse sentido, muitos métodos tem sido propostos para mitigar o problema [219, 237, 238], mas geralmente apresentam limitações, principalmente no que se refere à baixa repetibilidade dos resultados e à necessidade de serem aplicados várias vezes [237]. Um exemplo é a variante da SVM denominada máquina de vetor de suporte duplo com perda induzida por correntropia (*c-loss twin support vector machine*) [239]. Essa nova abordagem permite que o tempo computacional permaneça comparável ao de métodos relacionados, principalmente na resolução de problemas lineares, superando classificadores semelhantes em termos de robustez a outliers e precisão de classificação em problemas binários.

O resultado final do processo de otimização do classificador SVM $g(\mathbf{x})$ é apresentado nas Equações (2.23) e (2.24), em que a função linear $g(\mathbf{x})$ representa o hiperplano que separa as amostras com maior margem, sendo considerado aquele com melhor capacidade de generalização de acordo com a TAE [63]:

$$g(\mathbf{x}) = \text{sgn}(f(\mathbf{x})) = \text{sgn} \left(\sum_{\mathbf{x}_i \in \text{SV}} y_i \alpha_i^* \mathbf{x}_i \cdot \mathbf{x} + b^* \right) \quad (2.23)$$

$$b^* = \frac{1}{n_{\text{SV}}} \sum_{\mathbf{x}_j \in \text{SV}} \frac{1}{y_j} - \mathbf{w}^* \cdot \mathbf{x}_j \quad (2.24)$$

em que sgn representa a função sinal, α_i ($i = 1, 2, \dots, M_d$) é o i -ésimo multiplicador de Lagrange, SV (*support vector*) é o conjunto de n_{SV} vetores de suporte e os valores ótimos das variáveis são indicados por *. A Equação (2.23) evidencia que a regra de decisão do classificador otimizado é determinada pelos produtos internos entre os n_{SV} vetores de suporte $\mathbf{x}_i$ e o vetor de amostras de entrada $\mathbf{x}$.

No caso de padrões não-linearmente separáveis, o mapeamento para o espaço de características é realizado implicitamente pela aplicação da função kernel $\Phi(\cdot)$ aos vetores $\mathbf{x}_i$ e $\mathbf{x}$ (Equação (2.23)), resultando na Equação (2.25). Portanto, na SVM não-linear, o produto interno é definido implicitamente pela função kernel $\Phi(\cdot)$ no espaço de características, não havendo necessidade de determinar a função de mapeamento em si (Truque do Kernel) [63, 219].

$$g(\mathbf{x}) = \text{sgn}(f(\mathbf{x})) = \text{sgn} \left(\sum_{\mathbf{x}_i \in \text{SV}} y_i \alpha_i^* \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) + b^* \right) \quad (2.25)$$

Além de se utilizar funções kernel para expandir a potencialidade da SVM original, permitindo o tratamento de padrões não-linearmente separáveis, existem versões em que também é possível violar a margem de separação entre classes. Na SVM utilizada nesta pesquisa⁵, existe um fator de regularização denominado “restrição de caixa” (*BoxConstraint* – BC), cuja função é controlar a penalidade máxima imposta às observações que violam a margem de separação entre classes, permitindo, assim, prevenir o sobreajuste (*overfitting*). Quanto maior for o valor do hiperparâmetro BC, menos vetores de suporte serão gerados pelo classificador SVM, ocorrendo, no entanto, o aumento do tempo de treinamento [240, 241].

⁵ Implementada pela rotina `fitsvm` do MATLAB®2020.

A SVM geralmente apresenta melhor desempenho em problemas nos quais não se dispõe de um grande conjunto de dados para treinamento e teste, como mostram os exemplos a seguir.

No artigo [242], é apresentado um sistema para reconhecimento e classificação de gestos de mão estática, utilizando uma SVM multiclasse (*multiclass support vector machine* – MSVM) aplicada a um conjunto de dados obtido em cenários do mundo real. Os resultados obtidos indicam uma acurácia de 94% quando o sistema é treinado e testado em um conjunto de 350 exemplos relativos a 7 gestos de mão.

Um sistema de detecção e classificação automática para o diagnóstico precoce de arritmias cardíacas é apresentado em [243], a qual se baseia na extração de atributos de ECG, que são analisados e classificados usando MSVM. Uma acurácia de classificação de até 98% é alcançada para conjuntos de dados (treinamento e teste) compostos de 80 a 100 exemplos.

Considerando o bom desempenho da SVM em solucionar problemas envolvendo pequenos conjuntos de dados e sua boa generalização, esse classificador é amplamente empregado no reconhecimento de padrões, usados na detecção e diagnóstico de falhas em rolamentos. Assim sendo, é proposto em [233], uma SVM baseada no algoritmo de otimização de gafanhoto (*grasshopper optimization algorithm based support vector machine*), em que o algoritmo de otimização de gafanhoto (*grasshopper optimization algorithm*) é utilizado na otimização dos parâmetros da SVM, aumentando significativamente a capacidade de aprendizado e de generalização do método original. Nessa nova abordagem, obteve-se uma acurácia média de classificação de 98,9%, utilizando um conjunto de 89 exemplos para treinamento e teste.

2.5 Considerações Finais

Neste capítulo foi apresentada a fundamentação teórica em que se baseou esta pesquisa. Inicialmente, foi feita uma breve exposição sobre as principais características do sistema e do sinal SONAR, bem como sobre alguns aspectos relacionados ao ruído ambiental incidente, tais como suas fontes típicas e comportamento em frequência. Também foi discutida a ferramenta DEMON, tradicionalmente utilizada na análise espectral de sinais de SONAR passivo. Em seguida, apresentou-se os principais aspectos teóricos da HHT-EMD, em que se baseia o método proposto na pesquisa. Também foi feita uma comparação entre a HHT-EMD, a STFT, a WT e a WVD, métodos de representação TF usualmente utilizados na análise de sinais de SONAR passivo. Entre os aspectos teóricos da HHT-EMD que foram abordados, se destacam a baixa resiliência do método com relação à MM e ao ruído incidente, tendo sido apresentadas suas principais variantes e a VMD, métodos propostos para solucionar esses dois problemas. Na sequência, foram tratados os principais aspectos teóricos do método de redução de ruído utilizado, baseado na transformada wavelet Bark. Por fim, foram apresentados os modelos de classificação binária e os atributos investigados para a implementação do classificador de IMFs, parte integrante do sistema proposto na presente pesquisa, a ser apresentado no próximo capítulo.

3 Método Proposto e Sinais Utilizados

Neste capítulo, será apresentado o método proposto EMD-IRNI, a ser utilizado na análise TF de sinais de SONAR passivo com redução de ruído, e que se baseia na HHT-EMD.

O capítulo é organizado da seguinte forma. Inicialmente, são apresentados os sinais simulados e experimentais (Seção 3.1), que foram utilizados no desenvolvimento e avaliação do sistema proposto. Em seguida, são descritas as medidas de desempenho utilizadas na sua avaliação (Seção 3.2), durante as etapas de desenvolvimento e em sua versão final. Por fim, são apresentadas nas Seções 3.3 a 3.5, as três etapas de desenvolvimento do método proposto, que foram denominadas “Estudo de Caso 1”, “Estudo de Caso 2” e “Estudo de Caso 3”.


No Estudo de Caso 1 (Seção 3.3), é realizada uma investigação preliminar visando substituir a STFT, utilizada na análise DEMON padrão, pela HHT-EMD. O estudo consiste, basicamente, na avaliação e comparação de desempenho da HHT-EMD e de suas principais variantes, bem como da HHT-VMD.

No Estudo de Caso 2 (Seção 3.4), é realizada uma análise detalhada sobre os mecanismos de atuação do ruído ambiental incidente nesses sinais, bem como sobre métodos de filtragem a serem utilizados no sistema proposto para a mitigação do problema.

Por fim, no Estudo de Caso 3 (Seção 3.5), é apresentado o EMD-IRNI, um sistema inteligente de análise TF com redução de ruído das IMFs produzidas na decomposição EMD de sinais de SONAR passivo.

Na Figura 9, é apresentado um diagrama que resume o método EMD-IRNI. Nele são mostradas as etapas da análise DEMON padrão, discutidas na Seção 2.1.2, com a indicação de uma possível substituição da STFT pela HHT-EMD, conforme é proposto na presente pesquisa.

Figura 9 – Diagrama de blocos da análise DEMON padrão, indicando uma possível substituição da STFT pela HHT-EMD.



3.1 Sinais Utilizados

Neste trabalho, os sinais utilizados foram obtidos tanto por simulação [244], quanto por aquisições experimentais, tendo sido esses últimos disponibilizados pelo Instituto de Pesquisas da Marinha (IPqM), órgão vinculado à Marinha do Brasil, e também pela Universidade de Vigo, Espanha (banco de dados *ShipsEar*) [245].

Entre os sinais experimentais disponibilizados pela Marinha e do banco de dados *ShipsEar*, foram selecionados 40 sinais para formar o conjunto de dados utilizado na presente pesquisa. O critério de escolha estabelecido foi selecionar os sinais com um número total de amostras temporais maior ou igual a 10^4 (equivalente a ~ 200 s, para uma frequência de amostragem de $F_s = 31,250$ kHz e ~ 120 s, no caso de $F_s = 52,734$ kHz) após serem submetidos às etapas de demodulação e reamostragem, realizadas no pré-processamento da análise DEMON (Seção 2.1.2). O objetivo desse critério é garantir um número mínimo de amostras na janela de análise da IMF de mais baixo índice (IMF5), após a sequência de reamostragens realizadas com o sinal no processamento pelo sistema proposto (Seção 3.5.2). Tem-se, portanto, que foram utilizados sinais experimentais e simulados com duração superior a 120 s.

3.1.1 Sinais experimentais

- **Array Elíptico - Baía de Guanabara (conjunto 1)**

Este conjunto de sinais disponibilizado pela Marinha do Brasil foi adquirido na Baía de Guanabara, Rio de Janeiro, por um arranjo de hidrofones [246]. O cenário de aquisição consiste na passagem de um navio *offshore* (embarcação utilizada no apoio a plataformas de petróleo), que cruza com uma embarcação de pequeno porte. A imagem panorâmica (Figura 10a) apresenta o navio em diferentes posições, enquanto as Figuras 10b e 10c mostram, respectivamente, o arranjo de hidrofones e sua posição em relação ao deslocamento do navio. O arranjo de hidrofones é do tipo arco elíptico de 32 canais (*staves*). Cada canal vertical é composto por três hidrofones. Após a aquisição do sinal na forma analógica, é realizada a conversão analógico-digital com 24 bits, utilizando uma frequência de amostragem de $F_s = 31,250$ kHz. O sistema de aquisição engloba um filtro passa-baixa *anti-aliasing* com frequência de corte em 6,500 kHz e um filtro passa-alta com frequência de corte de 100 Hz.

Na Figura 10c, é possível identificar na parte central do arranjo de hidrofones (90°) a localização do *stave* responsável pela coleta dos sinal experimentais do conjunto 1. A Figura 12a mostra o resultado da análise DEMON aplicada a este sinal experimental (espectrograma e PSD média normalizada $\bar{P}(f)$, definida pela Equação (2.2)).

- **Array Cilíndrico - Águas Profundas (conjunto 2)**

Este conjunto, também disponibilizado pela Marinha do Brasil, é composto de dois sinais (M190 e M205) que foram adquiridos utilizando um arranjo cilíndrico com 24 *staves* (cada um monitorando $\sim 15^\circ$). Também nesse caso, foi usada a frequência de amostragem de $F_s = 31,250$ kHz. O arranjo foi instalado em uma embarcação, de modo que os sinais de algumas direções (marcações) foram contaminados pelo ruído próprio dessa embarcação.

Além disso, duas outras embarcações passaram ao mesmo tempo nas proximidades do arranjo, gerando sobreposição dos seus sinais, principalmente nas direções 190° e 205° (sinais M190 e M205). As características das embarcações envolvidas e o local de medição são sigilosos e não foram divulgados.

As análises DEMON dos sinais M190 e M205 (ambos com duração aproximada de 220 s) são apresentadas nas Figuras 12b e 12c, respectivamente (espectrograma e PSD média normalizada $\bar{P}(f)$, definida pela Equação (2.2)). Na Figura 12b, pode-se notar que a marcação M190 produz rotação de 146,5 rpm (1° harmônico), com um 2° harmônico em 293 rpm, caracterizando um navio de um eixo com duas pás [1]. Além disso, essa marcação sofre a interferência da marcação M205, por intermédio da rotação 120,1 rpm e do ruído próprio, pela rotação 304,7 rpm [1]. É importante salientar a proximidade entre os dois componentes de frequências 293 rpm e 304,7 rpm, o que provocou interferência cruzada entre as duas marcações e, conseqüentemente, a ocorrência de vazamento espectral. Por outro lado, a Figura 12c mostra que a marcação M205 produz uma rotação de 120,1 rpm e está sofrendo interferência apenas do ruído próprio, pela rotação 304,7 rpm [1]. Por fim, pode-se notar uma variação de velocidade dessa embarcação no intervalo aproximado [45 – 100] s, aumentando de 90,8 rpm para 120,1 rpm.

- **Array Linear - Costa Atlântica Espanhola (conjunto 3)**

Um dos maiores desafios na pesquisa, bem como no desenvolvimento de sistemas de processamento e classificação de sinais acústicos submarinos (UAS), é o acesso a sinais experimentais para validação desses sistemas, uma vez que usualmente são obtidos em operações militares sendo, portanto, de difícil acesso para pesquisadores e empresas civis por razões estratégicas [245]. Acrescente-se a isso o alto custo de investimento necessário para viabilizar o processo de aquisição desses sinais, em termos de equipamentos e recursos humanos.

Nesse sentido, pesquisadores da Universidade de Vigo (Espanha) disponibilizaram para a comunidade científica o banco de dados *ShipsEar* [247], composto de UAS produzidos por embarcações de vários tipos e tamanhos, trafegando em águas rasas da costa atlântica espanhola. Por terem sido adquiridos em condições reais, esses sinais contêm ruído ambiental gerado por fontes naturais e antropogênicas [245].

A Figura 11 ilustra o sistema de aquisição de sinal. Nesse caso, foi utilizado um conjunto de três hidrofones (H1, H2 e H3) posicionados verticalmente em linha em diferentes profundidades (c1, c2 e c3), a uma distância “a” da embarcação. Os hidrofones estão ancorados no fundo do mar e ligados a uma boia submersa, para garantir aproximadamente a verticalidade. Uma boia de superfície foi utilizada para facilitar a localização e recuperação. Foram usados gravadores acústicos digitais com frequência de amostragem $F_s = 52,734$ kHz para obter os dados experimentais [245]. Nas Figuras 13, 14 e 15 são apresentados os resultados da análise DEMON (espectrograma e PSD média normalizada $\bar{P}(f)$, definida pela Equação (2.2)) de três sinais integrantes do banco de dados *ShipsEar* que são utilizados nesta pesquisa, juntamente com as fotos das embarcações geradoras dos sinais.


Figura 10 – Cenário de aquisição do conjunto 1 de sinais experimentais da Marinha do Brasil [246]: (a) Vista panorâmica da Baía da Guanabara (Rio de Janeiro), mostrando a passagem do navio *offshore*, que cruza com uma embarcação de pequeno porte; (b) Arranjo de hidrofones e (c) Posicionamento do arranjo de hidrofones em relação ao navio.



(a)



(b)



(c)

Figura 11 – Cenário de aquisição do conjunto de sinais experimentais do banco de dados *ShipsEar* [245].




Figura 12 – Resultados da aplicação da DEMON aos sinais experimentais da Marinha do Brasil (espectrograma à esquerda e $\overline{P}(f)$ à direita): (a) *Array Elíptico* (Baía de Guanabara), (b) *Array Cilíndrico* (M190) e (c) *Array Cilíndrico* (M205).




Figura 13 – Análise DEMON do sinal acústico da balsa de passageiros **Mar de Onza** (banco de dados *ShipsEar* [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\bar{P}(f)$.



(a) Foto da embarcação saindo do porto de Vigo, na Espanha (Fonte: [244]).




Figura 14 – Análise DEMON do sinal acústico da balsa de passageiros **Mar de Cangas** (banco de dados *ShipsEar* [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\bar{P}(f)$.



(a) Foto da embarcação chegando ao porto de Vigo, na Espanha (Fonte: [244]).




Figura 15 – Análise DEMON do sinal acústico do navio de carga refrigerado **Eimskip Reefer** (banco de dados *ShipsEar* [247]): (a) Foto da embarcação; (b) Espectrograma e (c) PSD média normalizada $\overline{P(f)}$.




Tabela 1 – Informações dos sinais experimentais

Principais Características	Número de Sinais	Tipo de Ruído	Frequência de Amostragem
Conjunto 1 (2 embarcações se aproximando)	1	Irradiado (com ruído ambiente): 1	31,250 kHz
Conjunto 2 (2 embarcações se aproximando)	2	Irradiado (com ruído ambiente): 1	31,250 kHz
Conjunto 3 (vários tipos de embarcações chegando e saindo do porto)	37	Irradiado: 33 Ambiente: 4	52,734 kHz

Fonte: Elaborada pelo autor.

3.1.2 Sinais Simulados

O desenvolvimento de simuladores para teste de sistemas de SONAR passivo se justifica pelo alto investimento em equipamentos e recursos humanos necessários para a aquisição de sinais experimentais, e pela incerteza com relação às reais características de propagação marítima e condições ambientais no momento da aquisição. Isso tem motivado a implementação de simuladores que permitam o teste desses sistemas em diferentes condições de operação, durante a fase de projeto e desenvolvimento.


O simulador utilizado no presente trabalho é descrito em detalhes em [244], sendo capaz de sintetizar o ruído de cavitação irradiado por embarcações, juntamente com dois tipos diferentes de ruído ambiental (Estado do Mar e Chuva), em vários níveis de intensidade, conforme indicado na Seção 2.1.1. Ademais, ele também permite variar o nível médio do ruído de fundo (NMR, definido na Equação (2.3)) do espectro de frequência do sinal sintetizado, característica essa que

mostrou-se de grande importância durante a pesquisa, tendo em vista a baixa SNR dos sinais de SONAR passivo experimentais.

Diante da possibilidade de sintetizar sinais baseados nas características dos sinais reais, apenas variando o NMR, tornou-se viável avaliar o desempenho do método proposto sob condições menos severas de ruído, o que facilitou o andamento da pesquisa.

Três sinais simulados foram produzidos para representar condições variáveis de ruído acústico ambiental, semelhantes ao sinal experimental adquirido pela Marinha do Brasil na Baía de Guanabara (Figura 12a). No primeiro caso, o objetivo foi produzir condições de baixa intensidade de ruído ambiente (SS0: ruído estado do mar nível 0), fixando-se o valor do NMR do sinal simulado em torno de -25 dB, valor este aproximadamente 14 dB abaixo do NMR do sinal experimental. No segundo e terceiro casos, o objetivo foi avaliar os métodos de processamento de sinal em condições de ruído ambiental leve e moderado, utilizando ruído estado do mar nível 1 (SS1) e nível 3 (SS3), respectivamente (Seção 2.1.1). Levando em consideração as características do ruído de cavitação associado a esse sinal experimental, nos três casos o simulador foi configurado para operar com uma velocidade de rotação do eixo do hélice (composto por 3 pás) de 149,4 rpm [246]. Os resultados da análise DEMON do sinal simulado com SS0 são apresentados na Figura 16, em que é possível notar a proximidade com a versão experimental em que foi baseada a sua produção (Figura 12a).

Figura 16 – Resultados da aplicação da DEMON ao sinal simulado com SS0, baseado no sinal experimental da Marinha do Brasil, pertencente ao conjunto 1 (espectrograma à esquerda e $\bar{P}(f)$ à direita).




Finalmente, foi gerado um conjunto de 40 sinais simulados, tendo por base as principais características (número total de componentes espectrais, seus valores de amplitude e de frequência) dos sinais pertencentes ao conjunto de 40 sinais experimentais utilizados nesta pesquisa (sinais da Marinha e do banco de dados *ShipsEar*, descritos na Seção 3.1), porém fixando-se $\text{NMR} \approx -30$ dB para todos eles, o que se traduz como sendo uma condição bem menos rigorosa de ruído. O objetivo é comparar os resultados obtidos pelo sistema proposto na presente pesquisa, quando aplicado aos dois conjuntos de sinais, possibilitando, assim, avaliar a influência do ruído no desempenho geral do método proposto (Seção 3.5.3).

Na Figura 17a, são mostrados os resultados da análise DEMON aplicada ao sinal acústico do navio Eimskip Reefer (idênticos aos da Figura 15, repetidos aqui para fins de comparação), que integra o conjunto de 40 sinais experimentais, utilizado como referência na geração do conjunto de sinais simulados. Comparando esses resultados com os obtidos para a versão simulada

(Figura 17b), é visível a proximidade tanto entre os dois espectrogramas (à esquerda), como entre as duas representações da PSD média normalizada $\bar{P}(f)$ (à direita). Também é notória a relativa proximidade entre os valores de frequência dos componentes espectrais das duas representações (Figuras 17a e b), ficando os valores simulados, em média, $\sim 7,6$ rpm abaixo dos experimentais. Essa diferença se deve a limitações do simulador. Por fim, é importante ressaltar a diferença entre os valores dos níveis médios de ruído de fundo (NMR) que, no caso do sinal simulado (NMR = $-31,6$ dB), se localiza ~ 17 dB abaixo daquele relativo ao sinal experimental (NMR = $-14,2$ dB).

Figura 17 – Resultados da aplicação da análise DEMON ao sinal acústico do navio de carga refrigerado **Eimskip Reefer** e à sua versão simulada (espectrograma à esquerda e $\bar{P}(f)$ à direita): (a) Sinal experimental (banco de dados *ShipsEar* [247]) e (b) Sinal simulado.



3.2 Avaliação de desempenho

A seguir, são descritas as medidas de desempenho utilizadas na avaliação dos diversos métodos aplicados a sinais simulados e experimentais de SONAR passivo ao longo deste trabalho. A Figura 18 mostra um sinal genérico de SONAR passivo, com a indicação detalhada dos parâmetros gráficos usados nas Equações (3.1) a (3.3). É importante notar que, para possibilitar a comparação entre os diversos métodos abordados neste trabalho, foi utilizada a mesma resolução de frequência ($\Delta f = F_s/(2048)$) em todos eles:

1. O desvio percentual médio de frequência $\overline{\Delta F_p}$ (Equação (3.1)) é usado para avaliar a

acurácia da estimação do valor de frequência:

$$\overline{\Delta F_p} = \frac{1}{N_h} \sum_{q=1}^{N_h} \frac{|\widehat{F}_q - F_q|}{F_q} \cdot 100\% \quad (3.1)$$

em que $\widehat{F}_q$ e F_q ($q = 1, \dots, N_h$) são, respectivamente, os valores estimados dos N_h componentes de frequência detectados e seus valores verdadeiros (valores nominais de simulação). No caso dos sinais experimentais, tendo em vista a indisponibilidade de outras referências para os valores reais dos componentes de frequência, utilizou-se como valores nominais F_q , aqueles obtidos pela análise DEMON.

2. A relação sinal-ruído média $\overline{\text{SNR}}$ (em dB) representa a diferença média entre os valores de pico H_q dos componentes de frequência e o nível médio de ruído de fundo NMR (Figura 18). $\overline{\text{SNR}}$ indica o grau de resiliência ao ruído de fundo e pode ser calculado a partir das Equações (3.2) e (3.3):

$$\overline{\text{SNR}} = \frac{1}{N_h} \sum_{q=1}^{N_h} \text{SNR}_q = \frac{1}{N_h} \sum_{q=1}^{N_h} |H_q - \text{NMR}|. \quad (3.2)$$

$$\text{NMR} = \frac{2\Delta f}{F_s} \sum_{k=1}^{F_s/(2\Delta f)} h_q[k] \quad (3.3)$$

em que:

$$h_q[k] = \begin{cases} h_q[k_q - \delta], & \text{caso } k_q - \delta < k \leq k_q + \delta \\ h_M[k], & \text{caso contrário,} \end{cases}$$

$h_M[k]$ é a amplitude do MHS no índice de frequência k (Equação (2.14)), $k_q = F_q/F_s$ é a localização da frequência dos N_h componentes de frequência F_q e δ é o desvio de frequência discreta em torno de cada k_q , definindo a faixa em que os componentes de frequência são eliminados para o cálculo do valor NMR. O valor de δ é fixado empiricamente, com base no valor médio das larguras de banda dos mesmos componentes de frequência F_q detectados pela análise DEMON, tomadas no nível de ruído de fundo (NMR).

3. A largura espectral média $\overline{\Delta F}_{3\text{dB}}$, que estima a resolução de frequência dos componentes de frequência. Essa medida é calculada a partir da Equação (3.4), em que F_{q1} e F_{q2} são as frequências laterais medidas a -3dB a partir do valor de pico do componente.


$$\overline{\Delta F}_{3\text{dB}} = \frac{1}{N_h} \sum_{q=1}^{N_h} |F_{q1} - F_{q2}|. \quad (3.4)$$

4. A relação sinal-ruído SNR_i , $i = 1, 2, \dots, 5$, permite avaliar, de forma aproximada, o nível de ruído incidente na IMF_i , sendo calculada pela Equação (3.5), em que $C_i[k]$, $k = 1, 2, \dots, N_s$ é a transformada discreta de Fourier (*discrete Fourier transform* – DFT) de $c_i[n]$, $n = 1, 2, \dots, N_s$, sinal de tempo discreto da IMF_i (Equação (3.5)) [18].

$$\text{SNR}_i = 10 \log_{10} \left\{ \frac{A \sum_{q=1}^{N_h} \left[\sum_{k=k_q-\varepsilon}^{k_q+\varepsilon} |C_i[k]|^2 \right]}{B \left[\sum_{k=1}^{N_s} |C_i[k]|^2 - \sum_{q=1}^{N_h} \left(\sum_{k=k_q-\varepsilon}^{k_q+\varepsilon} |C_i[k]|^2 \right) \right]} \right\} \text{ dB} \quad (3.5)$$

em que ε é o desvio, no domínio discreto, em torno de cada índice k_q de localização dos N_h componentes de frequência F_q detectados. Define-se, dessa forma, a faixa em que os componentes de frequência $C_i[k]$ da IMF_i são computados para o cálculo da energia total do sinal-alvo. Os fatores $A = 1/(2N_h\varepsilon)$ e $B = 1/(N_s - 2N_h\varepsilon)$ foram introduzidos para normalização da largura de banda total efetiva, que abrange as bandas parciais centradas nos N_h componentes de frequência com índice k_q , nas quais é calculada SNR_i . O valor de ε é fixado empiricamente.

Figura 18 – Espectro de potência de um sinal genérico de SONAR passivo, com quatro componentes de frequência ($N_h = 4$), indicando os parâmetros gráficos usados no cálculo de $\Delta F_{3\text{dB}}$ e SNR .



A seguir, são apresentadas as três etapas de desenvolvimento do método proposto neste trabalho de pesquisa.

3.3 Estudo de Caso 1 - Aplicação da HHT em substituição à STFT na Análise DEMON

Nesta seção, é apresentado o método proposto para a avaliação de desempenho da HHT-EMD, de algumas das variantes (HHT-EEMD, HHT-CEEMDAN, HHT-ICEEMDAN e HHT-UPEMD) [16] e da HHT-VMD (Seção 2.2.5), aplicadas à análise DEMON de sinais simulados e experimentais de SONAR passivo (descritos na Seção 3.1). O objetivo é selecionar o método com melhor desempenho para integrar o sistema inteligente proposto no Estudo de Caso 3 (Seção 3.5).

Resumidamente, vamos comparar qualitativa e quantitativamente os desempenhos dos métodos baseados na HHT, com o atingido pela análise DEMON padrão, quando aplicados a esses sinais. A comparação qualitativa é feita pela análise visual dos resultados gráficos obtidos para as representações TF (espectrograma, no caso da DEMON e HS, no caso da HHT) e em

frequência (PSD média normalizada, no caso da DEMON e MHS, no caso da HHT). Quanto à avaliação quantitativa, comparamos os valores das medidas de desempenho (Seção 3.2) obtidos na aplicação dos vários métodos a esses sinais.

Na Figura 19a, é apresentado o diagrama de blocos do sistema utilizado na avaliação da HHT, com detalhes da estrutura interna do super-bloco HHT apresentado na Figura 19b. Esse sistema, referido como DEMON-HHT, foi implementado a partir de modificações da análise DEMON padrão (Figura 20). As mudanças são as seguintes:

- Substituição dos blocos STFT, NORMALIZA e Representação TF (Figura 20) pelo super-bloco HHT (semelhante ao mostrado na Figura 5), que passa a gerar, na DEMON-HHT (Figura 19), as representações em frequência (MHS) e em tempo-frequência (HS) do sinal $x[n]$;
- Substituição do bloco TPSW-F (Figura 20) pelo bloco TPSW-T e deslocamento desse último para dentro do super-bloco Pré-processamento (Figura 19a). Portanto, na DEMON-HHT, a filtragem TPSW passa a ser realizada no domínio do tempo.

Os sinais utilizados nas avaliações qualitativa e quantitativa dos diversos métodos foram os seguintes:

- **Experimental:** adquirido pela Marinha do Brasil na Baía de Guanabara (conjunto 1, na Seção 3.1.1);
- **Simulados:** SS0, SS1 e SS3 (Seção 3.1.2), versões sintetizadas (com modificações) a partir do sinal experimental do conjunto 1, adquirido pela Marinha (Seção 3.1.1).



No caso dos sinais de SONAR passivo, é possível determinar a banda de interesse, considerando-se aspectos específicos envolvidos em sua geração. No projeto mecânico dos navios, características como eficiência energética, hidrodinâmica e velocidade de deslocamento restringem a velocidade de cruzeiro mínima da rotação do eixo do hélice em aproximadamente 70 rpm [248]. Diante disso, para a análise dos sinais de SONAR passivo gerados por navios em velocidade de cruzeiro, não é esperado que existam componentes de frequência abaixo da faixa compreendida pela quinta IMF ($f < 50$ rpm). Portanto, para este trabalho, escolheu-se $N = 5$ para todos os casos analisados.

Em sequência às avaliações qualitativa (análise visual gráfica) e quantitativa (medidas de desempenho) dos métodos investigados, é realizada uma avaliação comparativa da resiliência à mixagem de modos (MM) [16] dos dois que obtiverem melhores resultados nas avaliações iniciais de desempenho. O objetivo é identificar qual deles é menos susceptível à ocorrência desse grave problema e que, conseqüentemente, pode gerar HS e MHS contendo componentes espectrais mais precisos e menos distorcidos.


Os sinais utilizados na avaliação da resiliência à MM dos métodos selecionados foram os seguintes:

- **Experimental:** Sinal acústico do navio Eimskip Reefer, integrante do banco de dados *ShipsEar* [245] (Figuras 15 e 17a). A escolha deste sinal específico, entre os vários disponíveis do conjunto 3, para a análise da MM foi motivada pelo fato de apresentar componentes harmônicos (um total de cinco) bem definidos, com amplitudes relativamente altas (no mínimo, 5 dB acima do NMR), o que facilita a detecção pela HHT-EMD e, conseqüentemente, a realização do ensaio;
- **Simulado:** Versão simulada do sinal acústico do navio Eimskip Reefer (Figura 17b).

Figura 19 – Diagrama de blocos da DEMON-HHT: (a) Diagrama geral; (b) Detalhes internos do super-bloco HHT.




Fluxo de Sinais :



(b)

Figura 20 – Diagrama de blocos da análise DEMON.




A utilização da HHT para representar sinais no domínio da frequência geralmente apresenta benefícios nos casos em que se deseja monitorar variações no tempo. Assim sendo, elaboramos um ensaio para estabelecer uma comparação entre os métodos investigados com melhor desempenho e a análise DEMON, aplicados a dois sinais experimentais pertencentes à base de dados *ShipsEar* (Seção 3.1.1), em que os navios monitorados alteram a velocidade do eixo do hélice ao longo do período monitorado (Figuras 13 e 14).

3.4 Estudo de Caso 2 - Estratégia de redução de ruído

Tendo em vista a sensibilidade ao ruído que caracteriza a HHT-EMD, considerando-se também as características específicas dos sinais de SONAR passivo experimentais (baixa SNR e compartilhamento da mesma banda de frequência com o ruído incidente), discutidas na Seção 2.2.6, realizou-se o Estudo de Caso 2, com o objetivo de definir a estratégia de redução de ruído a ser adotada na aplicação da HHT a sinais de SONAR passivo.

Na Figura 21, é mostrado o sistema de análise utilizado no Estudo de Caso 2, referido como DEMON-HHT-FILTRO. Esse sistema é baseado na DEMON-HHT (Figura 19), usada no Estudo de Caso 1 (Seção 3.3), e que foi modificada de forma a permitir a avaliação das técnicas de redução de ruído investigadas. A modificação realizada foi a introdução do bloco de filtragem das IMFs (destacado em cor).

Figura 21 – Diagrama detalhado do super-bloco HHT, que integra o sistema DEMON-HHT-FILTRO.



Para investigar o mecanismo de atuação do ruído no processamento HHT-EMD, a fim de descobrir a estratégia mais adequada para sua redução nas IMFs, realizamos dois ensaios:

- **Filtragem passa-faixa das IMFs:**

Neste caso, o bloco “Filtragem IMFs” do sistema de avaliação DEMON-HHT-FILTRO (Figura 21) é configurado como um conjunto de filtros passa-faixa lineares centrados nos componentes de frequência significativos de cada IMF gerada pela decomposição EMD. O objetivo do ensaio é investigar a influência do ruído incidente sobre o sinal analisado, no desempenho da HHT-EMD, identificando uma possível interconexão entre as parcelas desse ruído, presentes nas IMFs geradas, e a degradação provocada no HS e MHS.

Por se tratar de um procedimento de caráter investigativo e qualitativo, as características do filtro utilizado foram fixadas empiricamente, com base em medições realizadas da largura aproximada da banda de ruído das IMFs do sinal utilizado no ensaio (indicado a seguir). Após diversas realizações do ensaio, fixou-se as seguintes características: filtro de resposta finita ao impulso (*finite impulse response* – FIR) de ordem 415, largura de banda (BW) de

24 rpm, atenuação de banda de parada de 60 dB e ondulação (*ripple*) na banda passante de 0,2 dB.

O resultado obtido com esse método é comparado ao do procedimento adotado no Estudo de Caso 1 para sinais experimentais (conjunto 1).

- **Filtragem WTD das IMFs:**

Neste caso, o bloco “Filtragem IMFs” do sistema de avaliação DEMON-HHT-FILTRO (Figura 21) é configurado para realizar a filtragem WTD das IMFs geradas pela decomposição EMD. A filtragem é feita apenas com as IMFs contendo componentes de frequência significativos (IMF-T, definida na Seção 2.2.6). Foram avaliados e comparados dois métodos de filtragem WTD: a WTD-SWT (Seção 2.2.6) e a BWTD (Seção 2.3).

No caso da WTD-SWT, as características operacionais utilizadas são as seguintes: função wavelet mãe *Daubechies* 4 (db4) com quatro níveis de decomposição e limiar suave de filtragem (*soft threshold*), com valor a ser ajustado empiricamente. Esses parâmetros foram escolhidos a partir de artigos em que a WTD é usada na redução de ruído em UAS [249, 250]

No caso da BWTD, os parâmetros de construção da função wavelet Bark BWF (Seção 2.3) são os seguintes: banda de frequência linear $[0, F_s/2]$, número de subbandas $M = 100$ e limiar suave de filtragem. Esses parâmetros foram fixados empiricamente, com base em [214, 215, 216]. O ajuste dos valores do limiar de seleção Thr_m em cada uma das M subbandas também é realizado empiricamente, usando a estratégia apresentada no Apêndice C.2. O nível de redução de ruído obtido na aplicação da BWTD às IMFs é diretamente determinado pelo ajuste do valor desse limiar, podendo resultar em filtragem BWTD de baixa, média ou alta intensidade¹. O método de ajuste do limiar de filtragem wavelet Bark com limiar é uma contribuição da presente pesquisa.

O objetivo do ensaio é avaliar e comparar os dois métodos de filtragem WTD aplicados às IMF-T de um sinal experimental típico de SONAR passivo, verificando se o nível de redução de ruído que proporcionam é suficiente para mitigar a degradação do HS e MHS, sem perda significativa de informação útil eventualmente contida nas parcelas eliminadas desse sinal. O sinal experimental utilizado é o mesmo do ensaio anterior (conjunto 1, na Seção 3.1.1). Os dois métodos de filtragem foram avaliados com as IMF-T geradas tanto pela HHT-UPEMD, como pela HHT-VMD.

Ao longo deste trabalho, são adotadas as siglas “HHT-UPEMD-SWT” e “HHT-VMD-SWT” para designar o método de filtragem WTD-SWT aplicado às IMFs geradas pela HHT-UPEMD e HHT-VMD, respectivamente. De modo análogo, são utilizadas as siglas “HHT-UPEMD-BWTD” e “HHT-VMD-BWTD”.

Por fim, é realizada uma análise do comportamento dinâmico do método de filtragem WTD que obtiver o melhor desempenho nas avaliações qualitativa e quantitativa iniciais. Neste caso, é utilizado o sinal simulado produzido por uma embarcação hipotética (Seção 3.1.2).

¹ Essa terminologia é utilizada ao longo do trabalho.

3.5 Estudo de Caso 3 - Sistema Inteligente com redução de ruído

Uma vez escolhidos o método HHT com melhor desempenho no Estudo de Caso 1, bem como a estratégia de redução de ruído no Estudo de Caso 2, combinamos essas duas etapas no Estudo de Caso 3. Isso é feito por um sistema inteligente de análise TF de sinais de SONAR passivo com redução de ruído, denominado EMD-IRNI.

Essa nova estratégia é mostrada nos diagramas de blocos das Figuras 22 e 23 e consiste, basicamente, em extrair atributos das IMFs resultantes da decomposição UPEMD, para utilizá-los na classificação das IMFs em IMF-T e IMF-R (Seção 2.2.6). Após a separação, as IMF-R são descartadas e as IMF-T são tratadas para redução de ruído.

A Figura 22 apresenta o diagrama de blocos geral da EMD-IRNI, enquanto a Figura 23 mostra, em detalhes, a estrutura interna do seletor de IMFs, bloco central do sistema.

Figura 22 – Diagrama de blocos geral do sistema proposto EMD-IRNI.





Figura 23 – Diagrama de blocos detalhado do seletor de IMFs.



A seguir são descritas as etapas de processamento geral do sistema mostradas na Figura 22:

1. O sinal de SONAR passivo de entrada $s[n]$ passa pela mesma etapa de pré-processamento da análise DEMON (Figura 4), obtendo-se o sinal pré-processado $x[n]$;
2. Em seguida, é aplicada a decomposição UPEMD (Seção 2.2.5) ao sinal $x[n]$, obtendo-se as cinco primeiras IMF_i ($i = 1, 2, \dots, 5$);
3. Na sequência, as IMF_i , juntamente com o sinal $x[n]$, são processados pelo seletor de IMFs para obtenção das IMF-T, que são, então, filtradas pela BWTD (Seções 2.3 e 3.5.1) para redução de ruído. As IMF-R são descartadas;
4. A partir do somatório das IMF-T_f (IMF-T filtradas), é realizada a reconstrução do sinal original $x[n]$ com redução de ruído, obtendo-se o sinal reconstruído $x_{rec}[n]$;
5. Em seguida, é realizada a decomposição VMD (Seção 2.2.5) de $x_{rec}[n]$, gerando os componentes IMF_{vmd} , que são processados pela HT para a produção das IAs e IFs;
6. Finalmente, as IAs e IFs são utilizadas na construção do HS e MHS (Seção 2.2).

A seguir, são apresentadas as etapas de processamento do seletor de IMFs (Figura 23):

1. Realiza-se, inicialmente, uma pré-filtragem BWTD do sinal pré-processado $x[n]$, obtendo-se $x_f[n]$, ou seja, o sinal $x[n]$ com ruído reduzido (Seção 3.5.1);
2. Em seguida, é aplicada a decomposição UPEMD ao sinal $x_f[n]$, gerando o conjunto das IMF_f (cinco primeiras IMF_i filtradas);
3. Então é realizada uma subamostragem das IMF_f , visando normalizar a largura de banda em um valor equivalente (Seção 3.5.2). São produzidas as IMF_d (IMF_f decimadas);
4. Na sequência, é realizada a extração de atributos das IMF_d , utilizando uma estrutura de quadros formada por N_J janelas J_{ik} ($k = 1, 2, \dots, N_J$) de largura igual a WS (*window size*) amostras e fator de sobreposição entre janelas adjacentes igual a OL (*overlap*) amostras (Seções 3.5.2);
5. Finalmente, com base nos atributos extraídos, o classificador (Seção 3.5.3) seleciona as $IMF-T$ e descarta as $IMF-R$.

Seguindo o fluxo de processamento indicado nas Figuras 22 e 23, são analisados nas Seções 3.5.1 a 3.5.3 os principais blocos do EMD-IRNI.

3.5.1 Filtragem e pré-filtragem BWTD

A BWTD (Seção 2.3) é um dos métodos de filtragem WTD avaliados no Estudo de Caso 2 (Seção 3.4), e que é utilizado no sistema proposto EMD-IRNI com duas finalidades distintas:

1. No caso da pré-filtragem do sinal pré-processado $x[n]$, realizada no seletor de IMFs (Figura 23), o objetivo é propiciar o aumento da eficiência na extração dos atributos das IMF_d , os quais são usados pelo classificador na escolha da classe ($IMF-T$ ou $IMF-R$) dessas IMFs, tendo em vista a baixa resiliência ao ruído na extração dos cinco atributos investigados (Apêndice C.1). No entanto, a pré-filtragem não deve ser excessiva, a ponto de eliminar um número expressivo de coeficientes wavelet Bark $S_m[k]$ associados ao sinal de interesse contido em $x[n]$. Esse dilema é resolvido pelo posicionamento adequado do limiar de seleção Thr_m ($m = 0, 1, \dots, M - 1$) em cada uma das M subbandas (Apêndice C.2);
2. No caso da filtragem das $IMF-T$ produzidas pelo seletor de IMFs (Figura 22), o objetivo é a redução de ruído dessas IMFs para a obtenção das $IMF-T_f$, contendo componentes espectrais significativos com maior SNR. Isso se reflete na melhoria das características espectrais do HS e do MHS, que são construídos a partir desses componentes.

3.5.2 Extração de atributos

A extração de atributos² das IMF_i ($i = 1, 2, \dots, 5$) do sinal $x[n]$ é realizada no seletor de IMFs (Figura 23), com base na estrutura de quadros descrita anteriormente.

² A rigor, a extração de atributos é realizada nas cinco IMF_d , ou seja, após a pré-filtragem de $x[n]$ e subamostragem das IMF_f , conforme descrito anteriormente. No entanto, nos referimos às IMF_i , visando simplificar a notação.

Após a extração dos valores dos cinco atributos nos N_J quadros J_{ik} ($k = 1, 2, \dots, N_J$) da IMF_i , determina-se, para cada atributo, a mediana $M_d^{(i)}$ e o intervalo interquartil $IIQ^{(i)}$ (diferença entre o 1º e o 3º quartis) da distribuição dos N_J valores obtidos. A mediana $M_d^{(i)}$ fornece o valor central do atributo para a IMF_i , enquanto o intervalo interquartil $IIQ^{(i)}$ é uma medida do espalhamento em torno da mediana. Um desses dois parâmetros ($M_d^{(i)}$ ou $IIQ^{(i)}$) é, então, utilizado pelo classificador para a seleção das IMF-T. A opção por um deles é feita durante o processo de treinamento e validação do classificador (Seção 3.5.3), escolhendo-se aquele com o qual seja obtido melhor desempenho. Os cinco atributos investigados na pesquisa são definidos no Apêndice C.1.

No caso específico do atributo coeficiente ACF ($\rho_{xx}(\eta)$), o processo de extração dos valores de $M_d^{(i)}$ e $IIQ^{(i)}$ para a IMF_i é realizado como se segue:

1. Fixação do valor de η na faixa $[\eta_{\min} : \eta_{\max}]$, empiricamente determinada;
2. Determinação dos valores de $\rho_{xx}(\eta)$ nos N_J quadros J_{ik} ($k = 1, 2, \dots, N_J$) da IMF_i , ou seja, $\rho_{xx}^{(ik)}(\eta)$;
3. Cálculo da mediana da distribuição dos N_J valores determinados no passo (2), definida como $M_d^{(i,\eta)} = \text{med}(\rho_{xx}^{(ik)}(\eta))$, em que $\text{med}(\cdot)$ é o operador mediana;
4. Repetição dos passos (1) a (3) para todos os valores de $\eta \in [\eta_{\min} : \eta_{\max}]$, obtendo-se $N_J^{(\eta)}$ valores medianos $M_d^{(i,\eta)}$, em que $N_J^{(\eta)} = \eta_{\max} - \eta_{\min} + 1$;
5. Cálculo da mediana da distribuição dos $N_J^{(\eta)}$ valores determinados no passo (4), definida como $M_d^{(i)} = \text{med}(M_d^{(i,\eta)})$, e do intervalo interquartil $IIQ^{(i)}$ dessa mesma distribuição.

Como é mostrado em [16], a decomposição EMD pode ser modelada como um processo de filtragem diádica, em que a largura de banda útil diminui por um fator de 2 a cada nível de decomposição. Deste modo, para não introduzir uma tendência na estimação dos atributos (que são influenciados pela largura de banda do sinal), é aplicado um procedimento de subamostragens sucessivas (com fator FD) em cada i -ésimo nível de decomposição EMD antes do cálculo dos atributos. Esse procedimento é aplicado apenas no módulo de extração de atributos, não influenciando o processamento do sinal de interesse.

Finalmente, é importante destacar que a seleção dos atributos (entre os cinco investigados) a serem utilizados no sistema final é realizada durante o processo de definição do limiar de classificação (IIQ^L ou M_d^L) dos classificadores SVM e FDA (Seção 3.5.3), em que os desempenhos das várias combinações (em grupos de 2, 3, 4 ou 5) dos cinco atributos são avaliados e comparados.

3.5.3 Classificador de IMFs

O bloco “Classificador” (Figura 23), responsável pela seleção das IMF-T e eliminação das IMF-R, pode ser modelado como um sistema de classificação binária, em que a hipótese H_1 (associada à ocorrência do evento de interesse) é “a IMF analisada é do tipo IMF-T” (classe positiva), que deve ser selecionada e filtrada, enquanto a hipótese H_0 (associada à ocorrência

do evento não relevante) é “a IMF analisada é do tipo IMF-R” (classe negativa), que deve ser descartada.

Nos dois modelos de classificação binária investigados na presente pesquisa (SVM e FDA), são utilizados como entradas os cinco atributos definidos anteriormente. Os desempenhos dos dois classificadores, usando as várias combinações dos atributos (em grupos de 2, 3, 4 ou 5) e diversos valores dos hiperparâmetros, são avaliados e comparados, resultando na escolha do melhor deles, que passa a integrar o sistema proposto.

É importante ressaltar que a escolha dos modelos de classificação FDA e SVM teve como principal motivação a característica de apresentarem desempenhos interessantes em cenários nos quais não se dispõe de um grande conjunto de dados para treinamento e teste (Seções 2.4.1 e 2.4.2). No caso específico da presente pesquisa, o conjunto de dados disponível (treinamento e teste) é composto pelos 200 valores de atributos extraídos das cinco IMFs, obtidas a partir dos 40 sinais experimentais utilizados (Seção 3.1). Considerando que nas várias aplicações de FDA e SVM, indicadas pela literatura consultada (Seções 2.4.1 e 2.4.2), os conjuntos de dados possuem menos que 400 exemplos, a princípio podemos considerar adequada a opção por esses dois classificadores na presente pesquisa.

Existem diferentes métricas para a avaliação do desempenho de um classificador. Como mostrado na Figura 24, há quatro situações possíveis referentes ao resultado de uma classificação binária, dependendo da decisão do classificador para um dado exemplo pertencente à classe positiva (associada à hipótese H_1) ou negativa (associada à hipótese H_0) ser correta ou errada. Além dessas quatro métricas (parâmetros de desempenho), geralmente também são usadas a acurácia e a AUC. Os seis parâmetros de desempenho de classificação são definidos na Tabela 2, em que também são apresentadas as expressões analíticas usadas em seus cálculos.

O limiar de decisão para estimação de classes (limiar de discriminação) pode ser escolhido pela análise da curva característica de operação do receptor (*Receiver Operating Characteristics* - ROC) [251], gráfico bidimensional que ilustra o desempenho de um classificador binário em função deste limiar. A curva ROC é obtida plotando-se os valores da TVP e da correspondente TFP (Tabela 2), resultantes do processo de classificação, em várias configurações do limiar de discriminação. Um parâmetro importante da curva ROC é a AUC (Tabela 2).

A escolha do classificador para operar no sistema proposto EMD-IRNI é realizada pela avaliação da TVP, TFP, ACC e AUC.

Figura 24 – Ilustração de um sistema binário de classificação com seus possíveis resultados.




Tabela 2 – Parâmetros de desempenho de classificação, em que as quantidades de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos são indicadas por VP, VN, FP e FN, respectivamente.

Parâmetro de Desempenho	Definição	Expressão Analítica
Taxa de Verdadeiros Positivos (TVP)	Taxa de exemplos da classe positiva classificados corretamente.	$TVP = \frac{VP}{VP+FN}$
Taxa de Falsos Negativos (TFN)	Taxa de exemplos da classe positiva classificados incorretamente como pertencentes à classe negativa.	$TFN = \frac{FN}{VP+FN}$
Taxa de Verdadeiros Negativos (TVN)	Taxa de exemplos da classe negativa classificados corretamente.	$TVN = \frac{VN}{FP+VN}$
Taxa de Falsos Positivos (TFP)	Taxa de exemplos da classe negativa classificados incorretamente como pertencentes à classe positiva.	$TFP = \frac{FP}{FP+VN}$
Acurácia (ACC)	Indica o desempenho geral do classificador, a saber, qual a proporção de classificações corretas dentre todas as classificações realizadas.	$ACC = \frac{VP+VN}{VP+VN+FP+FN}$
Área sob a curva (<i>Area Under Curve</i> – AUC)	Mede a habilidade do classificador em distinguir as classes, traduzindo o desempenho geral de classificação.	Calculada a partir da análise da curva ROC.

Para ajustar a cadeia de pré-processamento e extração de atributos que alimentam o sistema de classificação (Figura 23), é preciso realizar a escolha dos parâmetros operacionais (hiperparâmetros) das referidas etapas. No caso da pré-filtragem, o hiperparâmetro é o fator de ajuste λ_2 do limiar de seleção dos coeficientes wavelet Bark (Equação (C.2)). Também é necessário ajustar o fator FD de subamostragem das IMFs (Seção 3.5.2). Finalmente, para extração de atributos, os parâmetros são a largura da janela de análise WS, o fator de sobreposição OL entre janelas adjacentes da estrutura de quadros e, no caso do atributo ACF, a faixa de LAGs $[\eta_{\min} : \eta_{\max}]$ usada no cálculo do coeficiente ACF ($\rho_{xx}(\eta)$) (Seção 3.5.2).

Nesta análise, a escolha dos hiperparâmetros é realizada com o objetivo de obter alta eficiência de classificação, considerando um limiar de classificação IIQ^L (M_d^L) aplicado aos atributos individualmente. Para isso, é utilizado um conjunto de 40 sinais experimentais de SONAR passivo (Seção 3.1). Nessa análise, utiliza-se como critério de eficiência a obtenção de uma taxa mínima de acerto (Taxa de Verdadeiros Positivos - TVP) de 90% para a classe das IMF-T (classe positiva), valor esse considerado suficiente para a preservação das IMFs potencialmente importantes na análise da assinatura espectral das embarcações. Uma vez fixado o TVP em 90%, o ponto de operação da curva ROC é escolhido de forma a minimizar a taxa de erro relativa à classificação de verdadeiras IMF-R como falsas IMF-T (Taxa de Falsos Positivos - TFP), o que resulta na maximização da SNR final.

O processo consiste em selecionar a combinação de hiperparâmetros associada ao limiar de classificação IIQ^L (M_d^L) obtido pela análise da curva ROC e que apresenta o menor valor de TFP para um TVP igual a 90%. A seleção dos parâmetros é realizada a partir da investigação de todas as possíveis combinações de valores dentro das faixas indicadas na Tabela 3, que foram fixadas conforme descrito no Apêndice C.3.

No caso específico do atributo coeficiente ACF ($\rho_{xx}(\eta)$), o limiar de classificação selecio-

nado IIQ^L passa a ser referido como IIQ^{ACF} .

Para os demais atributos, por analogia, IIQ^L será referido como IIQ^{PE} , IIQ^{SE} , IIQ^{PR} e IIQ^{MI} . No caso do limiar de classificação M_d^L , serão utilizados, especificamente, para cada atributo, M_d^{ACF} , M_d^{PE} , M_d^{SE} , M_d^{PR} e M_d^{MI} .

Tabela 3 – Faixas de valores dos hiperparâmetros utilizadas no processo de seleção dos limiares de classificação. São válidas para os cinco atributos.

FD	η_{max}	λ_2	OL	WS
[0,5:0,1:0,9]	[100:50:450]	[-2:1:2]	[0:0,1:0,9]	[500:10:4000]

Treinamento e Validação dos Classificadores

Tendo em vista o tamanho reduzido do conjunto total de dados experimentais disponíveis, com poucos exemplos (200 IMFs) para formar os subconjuntos de treinamento e de teste usados na seleção do classificador, optou-se pela realização de um processo de validação cruzada (VC). O objetivo principal desse procedimento é obter uma estimativa da flutuação estatística dos parâmetros de desempenho do classificador escolhido, quando operando em condições reais.

A VC é uma técnica de regularização usada para tentar evitar a ocorrência de sobreajuste (*overfitting*) no processo de treinamento do classificador [42, 252]. Nela são treinados e validados $N_R \times k$ classificadores, sendo N_R o número de sorteios realizados e k o número de subconjuntos, em que se divide o conjunto total de dados para se obter os subconjuntos de treino e de teste [42].

A seguir, são descritas as etapas do processo de VC, referido na literatura como validação cruzada *k-fold* (VC *k-fold*) [42]. O diagrama de blocos e a sequência de iterações associada ao processo, para o caso $k = 5$, são apresentados nas Figuras 25 e 26, respectivamente:

1. Sorteio: o conjunto total de dados experimentais, composto por 200 IMFs, é embaralhado aleatoriamente;
2. Divisão *k-fold*: o conjunto embaralhado é dividido em $k = 5$ subconjuntos (*folds*) de 40 IMFs (Figura 26). Considerando que o uso de conjuntos de dados de treinamento e de validação com poucos exemplos pode levar à oscilações nos resultados, optou-se por $k = 5$;
3. Seleção: um dos $k = 5$ subconjuntos (cada um com 40 IMFs) é selecionado e utilizado para validação do classificador treinado, enquanto os $k - 1 = 4$ subconjuntos restantes (160 IMFs) são selecionados e usados para o treinamento;
4. Treinamento e validação: do classificador, usando os subconjuntos selecionados na etapa 3;
5. Avaliação: com o objetivo de avaliar o desempenho do classificador treinado em cada i -ésima iteração do processo de VC (Figura 26), as classes estimadas durante a validação são confrontadas com as classes reais (padrão-ouro) e, a partir da contabilização dos erros e acertos, são calculados os parâmetros de desempenho (ACC, TVP e TFP);
6. Armazenamento: na i -ésima iteração do j -ésimo sorteio, o modelo do classificador treinado e os valores dos parâmetros de desempenho são armazenados para posterior utilização;

7. As etapas 3 a 6 são repetidas $k = 5$ vezes, alternando-se de forma circular o subconjunto de validação, conforme ilustrado na Figura 26;
8. Média: cálculo da média entre os k valores dos parâmetros de desempenho obtidos na etapa 5 do j -ésimo sorteio. Esses valores médios são armazenados para posterior utilização;
9. As etapas 1 a 8 são repetidas iterativamente por $N_R = 30$ realizações (sorteios). Temos, portanto, a geração de $N_R \times k = 150$ classificadores treinados, avaliados e armazenados.

Figura 25 – Diagrama de blocos da validação cruzada k -fold





Figura 26 – Indicação dos subconjuntos de treinamento e de teste usados na sequência de iterações (Fold i , $i = 1, 2, \dots, k$) do processo de validação cruzada k -fold ($k = 5$)



Os hiperparâmetros dos dois classificadores utilizados (FDA e SVM) são escolhidos empiricamente por um processo de pesquisa em grade (*grid search*), considerando os parâmetros de desempenho apresentados: ACC, TVP, TFP e AUC.

Conforme indicado na Tabela 4, além da combinação dos cinco atributos (em grupos de 2, 3, 4 ou 5), o classificador FDA possui o hiperparâmetro *DiscrimType*³, que define o método

³ Parâmetro da rotina *fitcdiscr* do MATLAB®2020, utilizada na implementação do classificador FDA.

variante da LDA utilizado (Seção 2.4.1). Caso *DiscrimType* assuma a opção linear, a variante selecionada será a RLDA. Caso seja escolhida a opção quadrática, a variante será a QDA. Tem-se, portanto, um conjunto de dois parâmetros, que são variados e testados, seguindo um processo de pesquisa em grade, para a escolha do classificador FDA com melhor desempenho.

Tabela 4 – Hiperparâmetro usado no treinamento e validação dos classificadores FDA.

Descrição	Parâmetros
<i>DiscrimType</i>	linear, quadrática

No caso do classificador SVM, além da combinação dos cinco atributos (em grupos de 2, 3, 4 ou 5), existem três hiperparâmetros⁴ (Seção 2.4.2), com valores indicados na Tabela 5:

- **Função *kernel***: que pode ser linear, quadrática, cúbica ou Gaussiana;
- ***BoxConstraint* (BC)**: fator de regularização, que pode ser qualquer número escalar positivo;
- ***KernelScale* (KS)**: fator de escala do *kernel* utilizado, podendo assumir qualquer valor escalar positivo;

Tem-se, portanto, um conjunto de quatro parâmetros, que são variados e testados, também seguindo um processo de pesquisa em grade, para a escolha do classificador SVM com melhor desempenho.

Tabela 5 – Hiperparâmetros usados no treinamento e validação dos classificadores SVM

Descrição	Parâmetros
Função <i>kernel</i>	linear, quadrática, cúbica e Gaussiana
BC	$\forall$ número escalar positivo
KS	$\forall$ número escalar positivo

Avaliação do classificador em operação no sistema

Uma vez escolhido o classificador com melhor desempenho (SVM ou FDA), o passo seguinte é avaliar o seu desempenho em operação na EMD-IRNI (Figuras 22 e 23). Nesse sentido, é realizada uma análise final, com a aplicação de todo o conjunto de 40 sinais experimentais utilizado no treinamento e validação dos classificadores.

Referindo-se ao diagrama de blocos da Figura 22, a análise final consiste no processamento, pelo sistema proposto, de todo o conjunto de 40 sinais experimentais. Para cada sinal de entrada $s[n]$ do conjunto, monitora-se a saída do seletor de IMFs, registrando-se o resultado da classificação (IMF-T ou IMF-R). Em seguida, os resultados registrados são comparados com as classes reais, indicadas no gabarito especialista (Tabela 24 do Apêndice D), contabilizando-se os parâmetros de desempenho TVP, TFP e ACC (Tabela 2).

⁴ Parâmetros da rotina `fitsvm` do MATLAB®2020, utilizada na implementação do classificador SVM.

Em seguida, tomando-se por base os quatro critérios adotados pelo especialista na construção do gabarito das classes reais (Tabela 24 do Apêndice D), é realizada uma análise detalhada dos sinais experimentais do conjunto, nos quais ocorreram erros de classificação pelo seletor de IMFs. Tal análise tem por objetivo principal identificar as origens desses erros, que possam estar associadas aos processos de construção do gabarito pelo especialista ou de treinamento/validação do classificador escolhido para o seletor de IMFs.

Em um outro ensaio, utiliza-se também sinais simulados, com o objetivo de avaliar a influência do ruído ambiente no desempenho geral do método proposto, ao se fixar uma condição menos rigorosa de $\text{NMR} \approx -30 \text{ dB}$ para os sinais simulados.

A avaliação consiste em comparar as eficiências de detecção do método nos dois casos (experimentais e simulados), baseando-se na distribuição das taxas de detecção⁵, e na distribuição dos desvios percentuais médio de frequência $\overline{\Delta F_p}$ (acurácia de estimação da frequência, definida pela Equação (3.1)), relativos aos 40 sinais simulados e aos respectivos sinais experimentais em que se baseiam.

⁵ Valor percentual da quantidade de componentes espectrais do sinal que são detectados pelo método.

4 Resultados

Neste capítulo, são apresentados os resultados dos três casos estudados na pesquisa.

4.1 Estudo de Caso 1 - Aplicação da HHT em substituição da STFT na Análise DEMON

Apresentamos nesta seção os resultados da avaliação de desempenho da HHT no Estudo de Caso 1. Primeiramente são apresentados e discutidos os resultados da avaliação qualitativa (análise visual gráfica) e quantitativa (medidas de desempenho) dos métodos aplicados a sinais simulados com três níveis de ruído ambiental (Seção 4.1.1) e a um sinal experimental (Seção 4.1.2). Em seguida, são apresentados os resultados da avaliação comparativa da resiliência à mixagem de modos (Seção 4.1.3) e do comportamento dinâmico (Seção 4.1.4) dos dois métodos que obtiveram melhor desempenho nas avaliações qualitativa e quantitativa iniciais.

Os hiperparâmetros utilizados na aplicação dos métodos são apresentados a seguir, tendo sido fixados empiricamente, com base na literatura indicada para cada um deles, e dentro das faixas de valores sugeridas nas rotinas computacionais (MATLAB®2020) utilizadas que implementam esses métodos, disponíveis em [253, 254]:

1. **EMD** - número máximo de iterações na etapa de peneiramento ($K_{\max}$) igual a 2000; utilização de uma função *spline* cúbica (*cubic spline*) para interpolar pontos entre cada par das sequências de pontos extremos (máximos e mínimos), e gerar, então, as envoltórias superior e inferior, respectivamente (Seção 2.2.2) [16];
2. **EEMD/CEEMDAN/ICEEMDAN** - valor RMS da amplitude do ruído (ε_0) igual a 0,7; número de realizações aleatórias (Γ) igual a 100; $K_{\max} = 5000$ [16, 196, 197];
3. **UPEMD** - número total de fases uniformemente distribuídas no intervalo $[0, 2\pi]$: $n_p = 32$; $\varepsilon_0 = 0,52$; $K_{\max} = 10$ [139, 16, 195].

Em todos os casos analisados com a aplicação dos vários dos métodos, foram consideradas apenas as cinco primeiras IMFs ($N = 5$), conforme as considerações apresentadas na Seção 3.3.

4.1.1 Desempenho em Sinais Simulados

Os resultados gráficos obtidos com a aplicação da análise DEMON padrão, dos métodos baseados na HHT-EMD (apenas os dois com melhor desempenho) e da HHT-VMD ao sinal simulado SS0 (Seção 3.1.2), são mostrados na Figura 27. As medidas de desempenho obtidas pela aplicação dos métodos analisados a esse mesmo sinal simulado são apresentadas na Tabela 6.

Uma comparação visual do HS e MHS (Figura 27.b a Figura 27.d) com o espectrograma e a PSD média normalizada $\bar{P}(f)$ (Figura 27.a), indica qualitativamente uma melhor resolução

em frequência dos métodos baseados na HHT-EMD e da VMD, quando comparados à análise DEMON, uma vez que o HS apresenta linhas espectrais mais finas e o MHS tem picos espectrais mais nítidos e bem definidos. Uma análise mais detalhada do componente de frequência ~ 298 rpm, indicado em destaque com escala expandida (intervalo $[100 - 200]$ s) nos HS resultantes da HHT-VMD (Figura 27.d), da HHT-ICEEMDAN e da UPEMD (Figuras 27.b e 27.c, respectivamente), mostra que, apesar dos três métodos apresentarem qualitativamente resoluções em frequência semelhantes, observa-se uma maior estabilidade na representação TF da HHT-VMD, tendo em vista a maior continuidade de suas linhas espectrais, quando comparadas às dos outros dois métodos. As intermitências observadas no HS da HHT-ICEEMDAN e, mais claramente, no caso da HHT-UPEMD, são ocasionadas por variações do valor detectado por esses dois métodos para o segundo componente de frequência, fixado em 298,8 rpm no intervalo total de duração $[0 - 320]$ s da simulação do sinal analisado SS0. Com relação ao MHS, qualitativamente também é visível a maior resolução da HHT-VMD em relação aos métodos baseados na HHT-EMD, por apresentar raias espectrais mais estreitas, em particular a do componente de frequência 597 rpm (no caso da HHT-VMD, na Figura 27.d), quando comparado aos componentes de frequências 589 rpm e 594,4 rpm (nos casos da HHT-ICEEMDAN e HHT-UPEMD, nas Figuras 27.b e 27.c, respectivamente). Essa avaliação qualitativa inicial é confirmada pelas medidas de desempenho obtidas pela aplicação dos métodos ao sinal simulado (Tabela 6).


Comparando os valores obtidos pelos diversos métodos aplicados ao sinal simulado SS0 (Tabela 6), pode-se notar que, de um modo geral, HHT-ICEEMDAN, HHT-UPEMD e HHT-VMD apresentaram os melhores desempenhos em relação à $\overline{\text{SNR}}$ (~ 25 dB maior que a da DEMON, no caso das variantes da HHT-EMD, e ~ 60 dB maior, no caso da HHT-VMD) e à redução de $\overline{\Delta F}_{3\text{dB}}$ (7 vezes, no caso da HHT-ICEEMDAN, 3,5 vezes, no caso da HHT-UPEMD e 14 vezes, no caso da HHT-VMD). Apenas para $\overline{\Delta F}_p$, o melhor resultado foi o da análise DEMON. Mas a HHT-CEEMDAN, HHT-ICEEMDAN, HHT-UPEMD e HHT-VMD também obtiveram valores relativamente baixos para esse último parâmetro ($\overline{\Delta F}_p < 1\%$), não havendo diferenças significativas entre eles para fins práticos. A HHT-VMD obteve a menor largura espectral média ($\overline{\Delta F}_{3\text{dB}} = 0,2$ rpm), 50% menor que a da HHT-ICEEMDAN, 75% menor que a da HHT-UPEMD e cerca de 93% menor que a da análise DEMON, possuindo, assim, maior resolução espectral dentre todos os métodos avaliados.

Tabela 6 – Medidas de desempenho para os diferentes métodos de processamento de dados simulados contaminados por ruído ambiental estado do mar de nível zero (SS0). Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.


Método	$\overline{\Delta F}_p$ (%) $\downarrow$	$\overline{\text{SNR}}$ (dB) $\uparrow$	$\overline{\Delta F}_{3\text{dB}}$ (rpm) $\downarrow$	Custo computacional (s) $\downarrow$ ¹
DEMON	0,01	24,7	2,8	1,6
HHT-EMD	5,67	28,3	1,7	0,7
HHT-EEMD	2,10	38,0	1,2	69,4
HHT-CEEMDAN	0,44	43,7	1,1	153,4
HHT-ICEEMDAN	0,74	54,8	0,4	114,2
HHT-UPEMD	0,23	51,9	0,8	0,7
HHT-VMD	0,09	89,4	0,2	5,6

¹ Configuração computacional utilizada: sistema operacional Windows 10 (64 bits), processador Intel Core i7 (2,9 GHz), RAM de 16 GB e plataforma MATLAB®2020.


Figura 27 – Resultados da aplicação dos métodos ao sinal simulado contaminado por ruído ambiental estado do mar de nível zero (SS0): (a) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita), (b) HHT-ICEEMDAN (HS à esquerda e MHS à direita), (c) HHT-UPEMD (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).




(a)



(b)



(c)



(d)

Por fim, o método que apresentou o maior custo computacional (*elapsed time*) foi a HHT-CEEMDAN (153,4s), seguido por sua variante HHT-ICEEMDAN (114,2s), valores esses cerca de 150 a 200 vezes maiores que os da HHT-EMD e HHT-UPEMD (0,7s), que apresentaram os menores custos. Considerando-se que o intervalo total de duração do sinal analisado é 320s, as aplicações da HHT-CEEMDAN e da HHT-ICEEMDAN em análises em tempo real (a exemplo da análise do comportamento dinâmico de embarcações) podem se tornar inviáveis.

Os resultados das simulações considerando a aplicação da análise DEMON, da HHT-UPEMD, da HHT-ICEEMDAN e da HHT-VMD em condições de ruído moderado são exibidos nas Figuras 28 e 29 e na Tabela 7.

Os resultados da aplicação da HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD aos sinais simulados com ruído estado do mar nível 0 (SS0), nível 1 (SS1) e nível 3 (SS3), apresentados, respectivamente, nas Figuras 27b, 28b e 29b (HHT-UPEMD), Figuras 27c, 28c e 29c (HHT-ICEEMDAN) e Figuras 27d, 28d e 29d (HHT-VMD), mostram um aumento da degradação do desempenho, uma vez que as linhas espectrais do HS se tornam cada vez mais irregulares e os picos espectrais do MHS ficam cada vez menos nítidos e com menor definição para os três métodos. Por outro lado, a análise DEMON realizada nos mesmos sinais (Figuras 27a, 28a e 29a, respectivamente), ainda mostra linhas espectrais bem definidas.

No entanto, os resultados da Tabela 7 indicam que os desempenhos das abordagens da HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD se mantêm superiores ao da análise DEMON para os três níveis de ruído, considerando aspectos como uma melhor resolução espectral, com valores de $\overline{\Delta F}_{3dB}$ cerca de 3 vezes (SS1) e 2 vezes (SS3) menores, no caso da HHT-UPEMD, cerca de 2 vezes menor (SS1 e SS3), no caso da HHT-ICEEMDAN e 14 vezes (SS1) e 5,6 vezes (SS3) menores, no caso da HHT-VMD. Além disso, um melhor desempenho também é alcançado para a $\overline{SNR}$, que foi entre 2 a 2,5 vezes maior para os três níveis de ruído, no caso da HHT-UPEMD e HHT-ICEEMDAN, e entre 3 a 3,6 vezes (SS0 e SS1) e 2,6 vezes (SS3) maior, no caso da HHT-VMD. Por fim, os valores crescentes de $\overline{\Delta F}_{3dB}$ e valores decrescentes de $\overline{SNR}$, ao se passar de SS0 para SS3, expressam uma crescente degradação do desempenho da HHT-UPEMD, HHT-ICEEMDAN e da HHT-VMD, caso a aplicação alvo tenha que enfrentar níveis crescentes de ruído.

É importante notar que, ao se adotar uma janela de análise para a STFT com $N_s = 1024$ amostras, a resolução em frequência do sinal simulado analisado é $\Delta f \simeq 1,5$ rpm. Este valor é calculado pela Equação (4.1), em que, após a reamostragem, $F_s = 50$ amostras/s (para os sinais experimentais dos conjuntos 1 e 2). Como este valor é maior que as resoluções de frequência ($\overline{\Delta F}_{3dB}$) da HHT-UPEMD e da HHT-VMD nos três níveis de ruído (Tabelas 6 e 7), calculadas (conforme mostrado na Seção 3.2) a partir dos valores obtidos por esses dois métodos, conclui-se que eles possuem seletividade suficiente para tratar o sinal simulado. No caso da HHT-ICEEMDAN, conforme mostrado na Tabela 7, temos seletividade espectral suficiente para tratar esse sinal somente no cenário de nível de ruído SS0 ($\overline{\Delta F}_{3dB} = 0,4$), caracterizado como sendo de baixa intensidade. Para os níveis de ruído com maior intensidade (SS1 e SS3), a resolução de frequência da HHT-ICEEMDAN ($\overline{\Delta F}_{3dB} = 1,5$) não é capaz de atingir o mínimo esperado (Δ_f) para o sinal simulado.

$$\Delta_f = \frac{F_s}{2 N_s}(60 \text{ rpm}) = \frac{50 \times 60}{2 \times 1024} \simeq 1,46 \text{ rpm} \quad (4.1)$$

Tabela 7 – Resultados da aplicação dos vários métodos ao sinal simulado contaminado por ruído ambiental estado do mar de vários níveis. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método. Em destaque de cor, os melhores valores dos três parâmetros, obtidos para cada nível de ruído incidente.

Nível de ruído	Método	$\overline{\Delta F_p}$ (%) $\downarrow$	$\overline{\text{SNR}}$ (dB) $\uparrow$	$\overline{\Delta F_{3\text{dB}}}$ (rpm) $\downarrow$
SS0	DEMON	0,01	24,7	2,8
	HHT-UPEMD	0,23	51,9	0,8
	HHT-ICEEMDAN	0,74	54,8	0,4
	HHT-VMD	0,09	89,4	0,2
SS1	DEMON	0,01	21,7	2,8
	HHT-UPEMD	1,11	56,4	0,9
	HHT-ICEEMDAN	4,58	49,8	1,5
	HHT-VMD	0,26	63,8	0,2
SS3	DEMON	0,01	18,5	3,0
	HHT-UPEMD	1,23	45,9	1,4
	HHT-ICEEMDAN	7,02	44,0	1,5
	HHT-VMD	2,09	48,52	0,5

Por fim, deve-se ressaltar que, como é mostrado na Tabela 7, ao ser submetida às duas condições de maior intensidade de ruído (SS1 e SS3), a HHT-ICEEMDAN apresentou pior desempenho do que a HHT-UPEMD e a HHT-VMD, não apenas com relação à resolução espectral $\overline{\Delta F_{3\text{dB}}}$ (conforme indicado na Tabela 7 e discutido no parágrafo anterior), mas também com respeito à acurácia ($\overline{\Delta F_p}$) e à $\overline{\text{SNR}}$. Enquanto a HHT-UPEMD e a HHT-VMD obtiveram, respectivamente, $\overline{\Delta F_p}$ igual a 1,11% e 0,26% (SS1), e $\overline{\Delta F_p}$ igual a 1,23% e 2,09% (SS3), a HHT-ICEEMDAN obteve valores desse parâmetro pelo menos 5 vezes maior (SS1) e 3 vezes maior (SS3). No caso da $\overline{\text{SNR}}$, a HHT-ICEEMDAN obteve valores próximos, porém inferiores, aos da HHT-UPEMD e HHT-VMD.

Considerando os resultados obtidos pelos vários métodos investigados (baseados na HHT-EMD e a HHT-VMD), ao serem aplicados ao sinal simulado em três níveis de ruído ambiental estado do mar, pode-se concluir que a HHT-VMD e a HHT-UPEMD apresentaram os melhores desempenhos, tanto na análise qualitativa (comparação visual das representações TF e em frequência), quanto na quantitativa (medidas de desempenho), demonstrando uma maior resiliência a esse tipo de ruído, quando comparadas à análise DEMON tradicional.

Figura 28 – Resultados dos métodos aplicados ao sinal simulado contaminado por ruído ambiental estado do mar nível SS1: (a) Análise DEMON (espectrograma à esquerda e $P(f)$ à direita); (b) HHT-UPEMD (HS à esquerda e MHS à direita), (c) HHT-ICEEMDAN (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).







Figura 29 – Resultados dos métodos aplicados ao sinal simulado contaminado por ruído ambiental estado do mar nível SS3: (a) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita); (b) HHT-UPEMD (HS à esquerda e MHS à direita), (c) HHT-ICEEMDAN (HS à esquerda e MHS à direita) e (d) HHT-VMD (HS à esquerda e MHS à direita).




(a)



(b)



(c)



(d)

4.1.2 Desempenho em Sinal Experimental

As Figuras 30c, 31a e 31c mostram, respectivamente, os resultados da aplicação da HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD, ao sinal experimental da Baía de Guanabara (Seção 3.1.1). Comparadas com as Figuras 30d, 31b e 31d, respectivamente, contendo os resultados dos três métodos aplicados à versão simulada SS0 desse sinal, é possível observar que, nos casos experimentais, as linhas espectrais do HS são menos retilíneas e há uma maior dispersão espectral no MHS. Esses aspectos podem ser explicados por uma menor relação sinal-ruído do sinal experimental (que foi adquirido em uma área altamente povoada e, portanto, sujeita a tráfego marítimo intenso). Os resultados da HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD também foram piores do que aqueles obtidos ao aplicar-se a análise DEMON ao mesmo sinal experimental (Figura 30a).

Comparando os valores das medidas de desempenho obtidos na aplicação da análise DEMON, HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD ao sinal experimental e ao simulado SS0 (Tabela 8), é visível o pior desempenho no primeiro caso para os quatro métodos. Com respeito à $\overline{\text{SNR}}$, a HHT-UPEMD, a HHT-ICEEMDAN e a HHT-VMD obtiveram, no caso experimental, valores cerca de 15 dB (HHT-UPEMD e HHT-VMD) e 22 dB (HHT-ICEEMDAN) menores que os obtidos no caso simulado. Com relação à largura espectral média $\overline{\Delta F}_{3\text{dB}}$, esses três métodos também apresentaram pior desempenho ao serem aplicados ao sinal experimental. Nesse caso, os valores obtidos pela HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD (3,1 rpm, 2,5 rpm e 2,2 rpm, respectivamente) são cerca de 4 vezes maior (no primeiro caso), 6 vezes maior (no segundo caso) e 11 vezes maior (no terceiro caso) que os do sinal simulado (0,8 rpm, 0,4 rpm e 0,2 rpm, respectivamente), ocorrendo, assim, uma degradação da resolução espectral no caso experimental, notadamente para a HHT-VMD.

Mesmo assim, como ocorreu no caso simulado, HHT-UPEMD, HHT-ICEEMDAN e HHT-VMD apresentaram, na situação experimental, uma maior $\overline{\text{SNR}}$ e uma menor $\overline{\Delta F}_{3\text{dB}}$, quando comparado com a análise DEMON (7,1 dB e 5,7 rpm, respectivamente). Isso confirma a maior resiliência ao ruído de fundo e a maior resolução espectral da HHT-VMD e dos dois métodos baseados na HHT-EMD.

Por fim, é importante ressaltar que, apesar da HHT-VMD apresentar melhor desempenho nas avaliações qualitativa e quantitativa (medidas de desempenho) em comparação à HHT-ICEEMDAN e HHT-UPEMD, tanto no caso experimental, como no caso simulado em vários níveis de ruído ambiental controlado (SS0, SS1 e SS3), esse método falhou na aplicação ao sinal experimental (Figura 31c), ao não conseguir detectar o componente de frequência $\sim 149,3$ rpm, presente no HS e MHS resultantes de sua aplicação à versão simulada do mesmo sinal (Figura 31d). Além disso, entre os três métodos, a HHT-VMD apresentou a maior degradação da resolução espectral ao ser aplicado ao sinal experimental, com valor de $\overline{\Delta F}_{3\text{dB}}$ cerca de 11 vezes maior do que o obtido para o sinal simulado com nível de ruído SS0 (Tabela 8). Esses dois aspectos referentes à aplicação da HHT-VMD a sinais experimentais sugerem uma relativa sensibilidade do método ao ruído ambiental específico incidente nesse tipo de sinal, o que contrasta com a característica de grande robustez ao ruído geralmente a ele associada na literatura (Seção 2.2.5).

Figura 30 – Resultados da aplicação da análise DEMON e da HHT-UPEMD ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara, e à sua versão simulada SS0: (a) Análise DEMON ao sinal experimental (espectrograma à esquerda e $\bar{P}(f)$ à direita), (b) Análise DEMON ao sinal simulado (espectrograma à esquerda e $\bar{P}(f)$ à direita), (c) HHT-UPEMD ao sinal experimental (HS à esquerda e MHS à direita) e d) HHT-UPEMD ao sinal simulado (HS à esquerda e MHS à direita).




Figura 31 – Resultados da aplicação da HHT-ICEEMDAN e da HHT-VMD ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara, e à sua versão simulada SS0 (HS à esquerda e MHS à direita): (a) HHT-ICEEMDAN ao sinal experimental, (b) HHT-ICEEMDAN ao sinal simulado, (c) HHT-VMD ao sinal experimental e (d) HHT-VMD ao sinal simulado.




Tabela 8 – Medidas de desempenho para os diferentes métodos de processamento do sinal experimental da Baía de Guanabara e de sua versão simulada SS0. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.

Método	SNR (dB) $\uparrow$ (experimental)	ΔF_{3dB} (rpm) $\downarrow$ (experimental)	SNR (dB) $\uparrow$ (simulado)	ΔF_{3dB} (rpm) $\downarrow$ (simulado)
DEMON	7,1	5,7	24,7	2,8
HHT-UPEMD	36,6	3,1	51,9	0,8
HHT-ICEEMDAN	32,8	2,5	54,8	0,4
HHT-VMD	74,0	2,2	89,4	0,2

4.1.3 Avaliação da Resiliência à Mixagem de Modos

Nesta seção, são apresentados os resultados obtidos na avaliação da resiliência à mixagem de modos (MM) da HHT-UPEMD e da HHT-VMD, métodos que alcançaram os melhores desempenhos nas avaliações qualitativa e quantitativa iniciais (Seções 4.1.1 e 4.1.2). Deve-se ressaltar que o objetivo dessa análise é identificar qual dos dois métodos é menos susceptível à ocorrência de MM e que, portanto, produz HS e MHS contendo componentes espectrais mais precisos e menos distorcidos. Essa avaliação foi realizada com o sinal experimental Eimskip Reefer (banco de dados *ShipsEar* [247]) e sua versão simulada (Figuras 17a e 17b, respectivamente).

Na descrição dos sinais experimentais utilizados nesta pesquisa (Seção 3.1.1), os resultados da análise DEMON do sinal acústico produzido pelo navio de carga Eimskip Reefer (Figura 32a), indicam se tratar de uma embarcação movida por um hélice de 5 pás (correspondentes aos cinco harmônicos do espectrograma e da $\bar{P}(f)$), que gira com velocidade ~ 472 rpm (frequência do primeiro harmônico). Com base em uma breve investigação sobre essa embarcação, adquirida pela empresa noruega Eimskip [255], especializada em transporte marítimo de carga sob refrigeração, obteve-se informações importantes sobre as especificações técnicas de projeto e construção do seu hélice [256], entre as quais, a de que pode ser constituído opcionalmente por 3, 4 ou 5 pás. Portanto, nesse caso específico, os resultados obtidos pela análise DEMON podem ser considerados confiáveis, concluindo-se, portanto, que o hélice da embarcação analisada muito provavelmente seja constituída de 5 pás, uma vez que são observados 5 componentes de frequências múltiplas no demograma.

Tendo em vista que a DEMON é utilizada como referência de comparação na presente pesquisa, os resultados obtidos pela HHT-UPEMD e HHT-VMD (Figuras 32b e 32c, respectivamente) aplicadas a esse sinal experimental também podem ser considerados igualmente confiáveis, uma vez que há cinco componentes espectrais significativos no conjunto de IMFs para ambos os métodos, e que o desvio percentual médio de frequência ($\overline{\Delta F_p}$ ²) ficou próximo de 0,5%.

Na análise dos sinais experimentais é perceptível uma maior distorção das linhas espectrais do HS no caso da abordagem HHT-UPEMD, bem como a presença de picos espectrais menos definidos ou totalmente indefinidos no MHS quando comparado à abordagem HHT-VMD. Essas distorções mais acentuadas no caso da HHT-UPEMD podem estar associadas a duas causas.

² Neste caso específico, utilizou-se no cálculo de $\overline{\Delta F_p}$ (Equação (3.1)), as frequências dos cinco componentes espectrais significativos das IMFs, como sendo os valores estimados $\widehat{F_q}$, e as frequências dos componentes de $\bar{P}(f)$ (DEMON), como valores nominais F_q .

A primeira é a ação do ruído incidente, enquanto a segunda é a ocorrência de MM entre os componentes 1428 rpm, 1906 rpm e 2381 rpm (IMF1), e os componentes 951,5 rpm e 1906 rpm (IMF2).

No caso da HHT-VMD (Figura 32c), é visível a maior separação dos componentes espectrais nas 4 primeiras IMFs. Apenas o componente 1906 rpm aparece mixado nas IMF1 e IMF2, mas com amplitude muito baixa, de modo que não se mostra presente no HS e MHS. O componente 2381 rpm da IMF1 é responsável pela geração do quarto harmônico do HS (~ 2153 rpm), que é bastante distorcido em comparação aos três primeiros, o que provavelmente é devido ao maior nível de ruído da IMF1.

Visando confirmar a interligação entre a ocorrência mais acentuada de MM nas IMFs da HHT-UPEMD (comparativamente à HHT-VMD) e a maior distorção verificada no HS e MHS, os dois métodos foram aplicados na versão simulada do sinal experimental da embarcação Eimskip Reefer. Assim procedendo, é minimizada uma possível influência do ruído na geração dessa distorção. Como mostra os resultados da análise DEMON do sinal simulado (Figura 33a), as linhas do espectrograma são mais visíveis e retilíneas e os picos espectrais da $\bar{P}(f)$ são mais agudos e definidos, em comparação aos do sinal experimental (Figura 32a). Por outro lado, o NMR do sinal simulado está ~ 18 dB abaixo do NMR do sinal experimental, sendo o primeiro, portanto, bem menos ruidoso.

Os resultados da aplicação da HHT-UPEMD (Figura 33b) e da HHT-VMD (Figura 33c) ao sinal simulado mostram que, assim como ocorreu no caso experimental, houve uma maior incidência de MM nas duas primeiras IMFs geradas pela HHT-UPEMD, como também uma maior distorção das duas últimas linhas espectrais do HS e um maior espalhamento espectral do MHS. Já no caso da HHT-VMD, não se verificou a ocorrência de MM, havendo a completa separação dos 5 componentes de frequência nas 5 primeiras IMFs. Além disso, é visível o melhor desempenho da HHT-VMD pela presença de linhas espectrais mais finas e retilíneas no HS e componentes de frequência com picos mais agudos e bem definidos no MHS. Esse experimento corrobora, portanto, a interligação entre a ocorrência de MM nas IMFs e a distorção dos componentes espectrais do HS e MHS.

Pelos resultados apresentados nesta seção, pode-se concluir que, ao ser aplicado a um sinal simulado e outro experimental de SONAR passivo, a HHT-VMD mostrou ser um método mais resiliente com respeito à mixagem de modos (MM) do que a HHT-UPEMD e, conseqüentemente, pode gerar representações TF (HS) e em frequência (MHS) contendo componentes espectrais mais precisos e menos distorcidos.

Figura 32 – Resultados dos métodos aplicados ao sinal experimental produzido pela embarcação Eimskip Reefer (banco de dados *ShipsEar* [247]): (a) Análise DEMON (espectrograma à esquerda e $\overline{P(f)}$ à direita), (b) HHT-UPEMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita) e (c) HHT-VMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita).





Figura 33 – Resultados dos métodos aplicados à versão simulada do sinal experimental produzido pela embarcação Eimskip Reefer (banco de dados *ShipsEar* [242]): (a) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita), (b) HHT-UPEMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita) e (c) HHT-VMD (IMFs à esquerda, HS no alto à direita e MHS em baixo à direita).



4.1.4 Avaliação do Comportamento Dinâmico

Nesta seção, são apresentados os resultados obtidos na avaliação do comportamento dinâmico dos métodos HHT-UPEMD e da HHT-VMD, que atingiram os melhores desempenhos nas avaliações qualitativa e quantitativa iniciais, tanto considerando sinais simulados (Seção 4.1.1) quanto o sinal experimental (Seção 4.1.2) de SONAR passivo. Na avaliação dinâmica, foram analisados os desempenhos apenas com sinais experimentais (Figuras 13 e 14).

Os resultados obtidos para o navio de passageiros que sai do Porto de Vigo (Figura 13) são apresentados na Figura 34. Uma concordância satisfatória pode ser observada entre os valores de frequência dos três componentes espectrais detectados pela análise DEMON (espectrograma) e aqueles obtidos pela HHT-UPEMD (HS). Também pode ser observado nas representações TF com escala expandida (zoom) da Figura 34 que a linha espectral para a frequência ~ 606 rpm é visível na faixa $[0 - 120, 7]$ s apenas para a HHT, revelando detalhes importantes da dinâmica de variação da velocidade do barco. Fato semelhante é observado para o componente de frequência em torno de ~ 354 rpm, que é interrompido em torno de ~ 95 s no espectrograma, mas é visível no HS em toda a faixa $[0 - 145]$ s. O componente em 1321 rpm, claramente visível no HS na mesma faixa, praticamente não aparece no espectrograma.

Os resultados para o navio de passageiros que chega ao Porto de Vigo (Figura 14) são apresentados na Figura 35. Também, neste caso, o HS mostra mais detalhes sobre a evolução temporal da frequência na banda $[802 - 811]$ rpm (ver escala de zoom), quando comparado ao espectrograma, permitindo obter mais informações sobre o comportamento dinâmico da embarcação nesse intervalo.

No caso da análise DEMON, a baixa resolução frequencial do espectrograma poderia induzir o operador do SONAR a uma falsa interpretação de que a descontinuidade da linha espectral de 802,3 rpm verificada aos 120,6 s, é originada em razão da aproximação de duas embarcações. Já no caso do HS, a maior resolução espectral permite se concluir com mais clareza que se trata da mesma embarcação, em que está ocorrendo uma significativa variação de velocidade de ~ 9 rpm durante o intervalo de ~ 120 s, sendo inclusive possível se calcular com relativa precisão o valor dessa variação. Considerando-se um possível cenário de rastreamento de um alvo pelo sistema SONAR de um submarino, a informação da variação de velocidade pode ser utilizada para localizar com precisão esse alvo.

Na Figura 36, são apresentados os resultados obtidos pela HHT-VMD (HS) aplicada aos mesmos sinais experimentais discutidos anteriormente. No caso da embarcação saindo do Porto de Vigo, apesar dos valores de frequência dos três componentes espectrais (352,3 rpm, 558,0 rpm e 1324 rpm) serem próximos aos obtidos pela análise DEMON e pela HHT-UPEMD, observa-se uma maior oscilação das linhas espectrais do HS resultante da HHT-VMD, em comparação às do HS da HHT-UPEMD (Figura 34). Algo semelhante também foi observado no caso da embarcação chegando ao Porto de Vigo, ou seja, uma maior oscilação das linhas espectrais na HHT-VMD em comparação à HHT-UPEMD (ver escala de frequência expandida das Figuras 36 e 34, respectivamente). Esse comportamento da HHT-VMD pode ter sido originado pela maior sensibilidade demonstrada pelo método ao ruído ambiental incidente em sinais experimentais de SONAR passivo, o que foi discutido no final da Seção 4.1.2.

Figura 34 – Resultados da aplicação da análise DEMON (esquerda) e da HHT-UPEMD (direita) ao sinal experimental do navio de passageiros que sai do Porto de Vigo (Espanha). No topo (escala de frequência normal): espectrograma (esquerda) e HS (direita). Na parte inferior (escala de frequência expandida): espectrograma (esquerda) e HS (direita).




Figura 35 – Resultados da aplicação da análise DEMON (esquerda) e da HHT-UPEMD (direita) ao sinal experimental do navio de passageiros que chega ao Porto de Vigo (Espanha). No topo (escala de frequência normal): espectrograma (esquerda) e HS (direita). Na parte inferior (escala de frequência expandida): espectrograma (esquerda) e HS (direita).





Figura 36 – Resultados da aplicação da HHT-VMD aos sinais experimentais dos navios de passageiros que sai (esquerda) e chega (direita) ao Porto de Vigo (Espanha). No topo, HS em escala de frequência normal. Na parte inferior, HS em escala de frequência expandida.



4.1.5 Considerações sobre o Estudo de Caso 1

Neste estudo, foi realizada a avaliação e comparação de desempenho da HHT-EMD, de suas principais variantes e da HHT-VMD, aplicadas a sinais experimentais e simulados de SONAR passivo. Em suma, fizemos uma análise inicial de aspectos qualitativos e quantitativos, seguida pelas avaliações da resiliência à mixagem de modos (MM) e do comportamento dinâmico dos métodos. As avaliações com sinais simulados foram feitas com três níveis de ruído ambiente estado do mar (SS0, SS1 e SS3). Em condições de ruído moderado (SS1 e SS3), verificou-se o aumento da degradação de desempenho dos métodos investigados, sendo ainda mais pronunciada no caso de sinais experimentais. Ainda assim, os resultados foram melhores que os obtidos pela análise DEMON, o que confirma a maior resiliência ao ruído dos métodos baseados na HHT-EMD e da HHT-VMD.

Entre os métodos investigados, a HHT-VMD e a HHT-UPEMD foram os que obtiveram os melhores resultados, no que se refere à acurácia, resolução espectral, resiliência à MM e comportamento dinâmico, se mostrando viáveis para substituir a STFT na análise DEMON padrão. Por isso, selecionamos estas duas abordagens para integrar o sistema proposto na presente pesquisa. Não obstante, tendo em vista a sensibilidade ao ruído ambiental demonstrada pelos dois métodos, ficou evidente a necessidade de se empregar uma estratégia de redução do ruído.

Finalmente, a avaliação do comportamento dinâmico revelou que ao serem aplicadas a sinais experimentais de SONAR passivo, a HHT-VMD e a HHT-UPEMD permitem obter informações mais detalhadas sobre a evolução temporal de eventos dinâmicos associados a embarcações (variação de velocidade, por exemplo), quando comparadas à análise DEMON padrão. Essa característica é um indicativo do potencial desses dois métodos para o rastreamento e localização precisa de alvos pelo sistema de SONAR passivo.

4.2 Estudo de Caso 2 - Estratégia de redução de ruído

Nesta seção, são apresentados os resultados da investigação sobre o mecanismo de atuação do ruído no processamento HHT-EMD de sinais experimentais de SONAR passivo, bem como sobre a estratégia adotada para sua redução, conforme método proposto na Seção 3.4. Tendo em vista os melhores desempenhos obtidos pela HHT-VMD e HHT-UPEMD no Estudo de Caso 1 (Seção 4.1), esses dois métodos de análise foram selecionados e utilizados nas duas investigações.

4.2.1 Filtragem passa-faixa das IMFs

O ensaio investigativo sobre a atuação do ruído consiste em uma filtragem linear passa-faixa das IMF-T obtidas pelos dois métodos selecionados, considerando o sinal experimental adquirido pela Marinha do Brasil na Baía de Guanabara (Seção 3.1.1), por meio do sistema DEMON-HHT-FILTRO (Figura 21).

Como pode ser notado nas três IMFs produzidas pela HHT-UPEMD (Figura 37a), os componentes-significativos em 148,0 rpm, 296,2 rpm e 592,2 rpm compartilham a mesma banda de frequência com sinais de perfil passa-banda, indicando, portanto, que podem ser consideradas IMF-T, conforme definição do Apêndice D. Analisando o HS e MHS associados a esse conjunto de IMFs (Figura 37a), são visíveis as linhas espectrais irregulares no HS e o intenso espalhamento espectral no MHS, o que já havia sido constatado no Estudo de Caso 1 (Figura 30).

Considerações semelhantes são feitas para os resultados obtidos na realização deste mesmo ensaio com a HHT-VMD (Figura 38a), em que foram produzidas duas IMF-T contendo os componentes-significativos em 296,2 rpm e 592,2 rpm. Analisando o componente de frequência 148,0 rpm, detectado na IMF2 (Figura 38a), percebe-se que ele possui amplitude cerca de 2,5 vezes menor que a do componente 296,2 rpm (com o qual está mixado), e um valor de pico bem abaixo do nível máximo da banda de ruído. Assim sendo, este componente não pode ser considerado significativo (Apêndice D) e, conseqüentemente, não aparece no HS e MHS (Figura 38a). Essa falha na detecção do componente de 148,0 rpm do sinal experimental da Baía de Guanabara foi analisada no Estudo de Caso 1 (Seção 4.1.2), tendo sido atribuída a uma provável sensibilidade da HHT-VMD ao ruído ambiental incidente em sinais experimentais de SONAR passivo.

Conforme mostrado nas Figuras 37b e 38b, relativas à HHT-UPEMD e HHT-VMD, respectivamente, a degradação dos componentes de frequência do HS e MHS quase desaparece por completo com a filtragem passa-faixa, dando lugar a linhas espectrais bem retilíneas no HS e componentes espectrais com picos nítidos e bem definidos no MHS. Os desvios percentuais médios de frequência relativos à HHT-UPEMD e HHT-VMD foram, respectivamente, $\overline{\Delta F_p} = 0,5\%$ e $\overline{\Delta F_p} = 0,03\%$, valores esses calculados com base naqueles estimados pela análise DEMON (Figuras 37c e 38c), e que são relativamente próximos aos obtidos com a aplicação dos dois métodos ao sinal simulado com nível de ruído SS0, no Estudo de Caso 1 (Tabela 7).

Portanto, parece que o ruído presente nos sinais de SONAR passivo tem um papel importante na degradação do HS e do MHS, obtidos com a aplicação da HHT. Como os sinais experimentais de SONAR passivo são geralmente bastante ruidosos, podemos supor que esses sinais passa-banda são ruídos ambientais e as IMFs analisadas são IMF-T.

Figura 37 – Resultados dos métodos aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) HHT-UPEMD ao sinal original (IMFs ruidosas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito), (b) HHT-UPEMD ao sinal sem ruído (IMFs filtradas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito) e (c) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita).





Figura 38 – Resultados dos métodos aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) HHT-VMD ao sinal original (IMFs ruidosas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito), (b) HHT-UPEMD ao sinal sem ruído (IMFs filtradas no domínio da frequência à esquerda, HS no canto superior direito, MHS no canto inferior direito) e (c) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita).



No entanto, é importante ressaltar que a filtragem linear utilizada neste ensaio tem caráter apenas investigativo, não pretendendo ser uma solução definitiva para a redução de ruído nas IMFs. Com efeito, existem dois problemas relacionados a essa estratégia. O primeiro deles é a dificuldade de projetar filtros passa-faixa centrados em cada componente espectral, tendo em vista a necessidade de se conhecer, a priori, o valor da frequência do componente e a largura aproximada da banda de ruído a ser eliminada em torno desse componente, aspectos esses que são variantes para cada IMF. Além disso, a filtragem linear poderia causar, como efeito colateral, a perda de informações importantes associadas a características estáticas (assinatura espectral de uma embarcação, por exemplo) ou dinâmicas, eventualmente contidas nas parcelas da banda compartilhada que fossem eliminadas.

4.2.2 Filtragem WTD das IMFs

Seguindo o método descrito para este ensaio (Seção 3.4), inicialmente configurou-se o sistema DEMON-HHT-FILTRO (Figura 21) para realizar as filtrações HHT-UPEMD-SWT e HHT-VMD-SWT³ das IMF-T geradas na decomposição do sinal experimental adquirido na Baía de Guanabara (Seção 3.1.1). A seguir, comparou-se as IMF-T filtradas, o HS e o MHS obtidos, nos casos da HHT-UPEMD-SWT (Figura 39) e da HHT-VMD-SWT (Figura 40), com aqueles anteriores aos dois processos de filtragem (Figuras 37a e 38a, respectivamente).

Como previsto nas considerações teóricas da Seção 2.2.6, a abordagem usando WTD-SWT reduziu visivelmente o nível de ruído nas bandas laterais em torno dos componentes espectrais detectados nas IMF-T (Figuras 39 e 40), em comparação ao sinal ruidoso original (Figuras 37a e 38a, respectivamente) sem, no entanto, levar a uma perda significativa de informação. Em ambos os casos, o HS e o MHS associados às IMF-T filtradas pela WTD-SWT (Figura 39, no caso da HHT-UPEMD e Figura 40, no caso da HHT-VMD), apresentaram menor distorção, com linhas espectrais mais retilíneas (HS) e menor espalhamento espectral (MHS).

Comparando os valores das medidas de desempenho da HHT-UPEMD-SWT, mostrados na Tabela 9 ($\overline{\text{SNR}} = 55,9 \text{ dB}$ e $\overline{\Delta F}_{3\text{dB}} = 1,8 \text{ rpm}$), com aqueles relativos às IMF-T originais (geradas na aplicação da HHT-UPEMD ao sinal experimental ruidoso), verifica-se um aumento de $\sim 19 \text{ dB}$ da $\overline{\text{SNR}}$ e um decréscimo de $\sim 42\%$ de $\overline{\Delta F}_{3\text{dB}}$, o que indica uma diminuição do nível de ruído de fundo e um aumento significativo da resolução espectral, obtidos com a filtragem WTD-SWT. Esses valores também foram melhores que os da HHT-ICEEMDAN ($\sim 70\%$ maior e 28% menor, respectivamente) e da análise DEMON (cerca de 8 vezes maior e 3 vezes menor, respectivamente). Além disso, o desvio percentual médio de frequência da HHT-UPEMD-SWT ($\overline{\Delta F}_p = 1,3\%$) é $\sim 58\%$ menor que o da HHT-VMD e 7 vezes menor que o da HHT-UPEMD, concluindo-se que também houve um aumento significativo da acurácia com a aplicação da WTD-SWT.

Interessantemente, os valores das medidas de desempenho da HHT-VMD-SWT (Tabela 9) foram ainda melhores que os obtidos pela HHT-UPEMD-SWT, ao apresentar $\overline{\Delta F}_p$ cerca de 6 vezes menor, $\overline{\Delta F}_{3\text{dB}}$ aproximadamente 28% menor e $\overline{\text{SNR}}$, 6 dB maior.

³ Siglas adotadas para designar o método WTD-SWT aplicado às IMFs geradas pela HHT-UPEMD e HHT-VMD, respectivamente.

Na segunda etapa deste ensaio, configurou-se o sistema DEMON-HHT-FILTRO (Figura 21) para realizar as filtrações HHT-UPEMD-BWTD e HHT-VMD-BWTD⁴ do sinal experimental adquirido pela Marinha do Brasil na Baía de Guanabara (Seção 3.1.1). Seguindo um processo de análise semelhante ao descrito anteriormente, para os casos das filtrações HHT-UPEMD-SWT e HHT-VMD-SWT, obteve-se os resultados gráficos apresentados nas Figuras 41 e 42, respectivamente.

Como pode ser visto na Figura 41, a filtração BWTD das IMF1, IMF2 e IMF3 praticamente eliminou as bandas laterais em torno dos componentes com frequências 592,5 rpm, 296,1 rpm e 148,2 rpm, respectivamente, preservando, no entanto, esses componentes de interesse. Nesse caso específico, a eliminação das bandas laterais provavelmente não provoca uma eventual perda de informações estáticas ou dinâmicas importantes. Tal conclusão se baseia nos resultados da análise DEMON do mesmo sinal (Figura 37c), em que se observa no espectrograma a presença de linhas contínuas e retilíneas, indicando a ausência de variações relevantes da velocidade da embarcação e de outros eventos significativos. Portanto, nesse caso específico, as informações de interesse provavelmente se restringem à assinatura espectral da embarcação (frequência do primeiro componente harmônico e o número total de harmônicos).

Comparando visualmente o HS e o MHS obtidos após a filtração HHT-UPEMD-BWTD (Figura 41), com aqueles relativos ao sinal original (Figura 37a) e à filtração HHT-UPEMD-SWT (Figura 39), analisada anteriormente, no primeiro caso, as linhas espectrais do HS são mais retilíneas, enquanto o MHS apresenta componentes de frequência com picos mais agudos e definidos, e um menor espalhamento espectral.

O melhor desempenho da HHT-UPEMD-BWTD em relação à HHT-UPEMD-SWT, verificado na avaliação qualitativa visual, foi confirmado pelos valores das medidas de desempenho do primeiro método (Tabela 9). No que se refere à $\overline{\Delta F}_p$, $\overline{\text{SNR}}$ e $\overline{\Delta F}_{3\text{dB}}$, a HHT-UPEMD-BWTD alcançou uma diminuição de $\sim 45\%$, um aumento de $\sim 25\text{ dB}$ e um decréscimo de $\sim 78\%$, respectivamente. Comparada à HHT-VMD, HHT-UPEMD, HHT-ICEEMDAN e análise DEMON, essa técnica também apresentou melhor desempenho com respeito às três medidas de desempenho avaliadas (Tabela 9).

Na Figura 42, são apresentados os resultados gráficos obtidos com a aplicação da HHT-VMD-BWTD ao sinal experimental da Baía de Guanabara (Seção 3.1.1). Também neste caso, a filtração BWTD das IMF1, IMF2 praticamente eliminou as bandas laterais em torno dos componentes com frequências 592,2 rpm e 296,2 rpm, respectivamente, preservando, no entanto, esses componentes de interesse. Pode-se observar a maior resolução em frequência desse método em relação a todos os demais, tendo em vista apresentar HS com linhas espectrais mais estreitas e retilíneas e MHS constituído por componentes de frequência com picos mais agudos e definidos. Os valores das medidas de desempenho (Tabela 9) confirmam essa avaliação qualitativa inicial, considerando que a HHT-VMD-BWTD obteve $\overline{\Delta F}_p$ vinte e quatro vezes menor, $\overline{\text{SNR}} \sim 24\text{ dB}$ maior e $\overline{\Delta F}_{3\text{dB}}$ 50% menor, em comparação aos valores da HHT-UPEMD-BWTD.

⁴ Siglas adotadas para designar o método BWTD aplicado às IMFs geradas pela HHT-UPEMD e HHT-VMD, respectivamente.

Tabela 9 – Medidas de desempenho para os diferentes métodos de processamento do sinal experimental da Baía de Guanabara. Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.

Método	ΔF_p (%) $\downarrow$	SNR (dB) $\uparrow$	ΔF_{3dB} (rpm) $\downarrow$
DEMON	0,01	7,1	5,7
HHT-ICEEMDAN	1,24	32,8	2,5
HHT-UPEMD	9,22	36,6	3,1
HHT-UPEMD-SWT	1,30	55,9	1,8
HHT-UPEMD-BWTD	0,72	81,1	0,4
HHT-VMD	3,08	74,0	2,2
HHT-VMD-SWT	0,21	61,5	1,3
HHT-VMD-BWTD	0,03	105,3	0,2

Figura 39 – Resultados da WTD-UPEMD-SWT aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).




Figura 40 – Resultados da WTD-VMD-SWT aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).




Figura 41 – Resultados da HHT-UPEMD-BWTD aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).





Figura 42 – Resultados da HHT-VMD-BWTD aplicada ao sinal experimental adquirido na Baía de Guanabara: IMFs sem ruído (esquerda), HS (superior direito) e MHS (inferior direito).



4.2.3 Considerações sobre o Estudo de Caso 2

As estratégias de filtragem SWT e BWTD proporcionaram melhoria de desempenho, tanto na aplicação às IMF-T produzidas pela HHT-UPEMD quanto àquelas geradas pela HHT-VMD. Nos quatro casos avaliados (HHT-UPEMD-SWT, HHT-VMD-SWT, HHT-UPEMD-BWTD e HHT-VMD-BWTD), verificou-se substancial redução do nível de ruído, levando, consequentemente, a HS e MHS contendo componentes espectrais menos oscilantes, em comparação à condição sem filtragem.

As análises realizadas com o sinal experimental adquirido pela Marinha do Brasil na Baía de Guanabara, assim como com um sinal especificamente sintetizado para a avaliação do comportamento dinâmico (variação da velocidade de uma embarcação), indicaram o melhor desempenho da HHT-VMD-BWTD.

Portanto, a conclusão geral do Estudo de Caso 2 é que a filtragem BWTD, aplicada às IMF-T produzidas pela HHT-VMD, foi o método mais acurado, com maior resolução espectral, melhor comportamento dinâmico e que proporciona a maior redução de ruído, dentre os quatro avaliados. No entanto, tendo em vista a maior sensibilidade ao ruído ambiental incidente em sinais experimentais de SONAR passivo, demonstrada pela HHT-VMD no Estudo de Caso 1 (com consequente degradação da resolução espectral), além da HHT-VMD-BWTD, também foi selecionada a HHT-UPEMD-BWTD (método que obteve a segunda melhor avaliação) para integrarem conjuntamente o sistema final proposto neste trabalho.

Finalmente, uma ressalva deve ser feita. No caso específico do sinal experimental analisado neste estudo (adquirido pela Marinha do Brasil na Baía de Guanabara), a eliminação realizada pela filtragem BWTD com média intensidade, de parcelas das bandas de frequência compartilhadas nas IMF-T, provavelmente não provocou perdas de informações estáticas ou dinâmicas importantes. No entanto, em cenários reais nos quais não se sabe a priori as características estáticas (relacionadas à construção do hélice, por exemplo) e dinâmicas da embarcação, a eliminação de parcelas das bandas compartilhadas nas IMF-T deve ser realizada de forma gradual, respeitando um limiar adequado que deve ser pré-fixado. Nesse sentido, torna-se necessária uma estratégia de ajuste dinâmico e iterativo (por parte do operador SONAR) dos parâmetros de filtragem BWTD (Seção 3.4), visando a redução do ruído sem, no entanto, eliminar informações importantes.

4.3 Estudo de Caso 3 - Sistema Inteligente com redução de ruído

Nesta seção, são apresentados os resultados do processo de desenvolvimento do EMD-IRNI, sistema inteligente proposto no presente trabalho para análise TF de sinais de SONAR passivo com redução de ruído. Esses resultados foram obtidos com base no método descrito na Seção 3.5, utilizado na implementação dos vários blocos que integram o sistema proposto (Figuras 22 e 23).

4.3.1 Limiares de classificação

Nesta seção são apresentados os resultados do processo de definição dos limiares de classificação (IIQ^L ou M_d^L) relativos aos cinco atributos, processo esse apresentado na Seção 3.5.3. Tendo em vista o melhor desempenho obtido com o atributo $\rho_{xx}(\eta)$ (coeficiente ACF) em comparação aos demais atributos, serão apresentados e discutidos com mais detalhes os resultados relativos a esse atributo, ou seja, a definição de IIQ^{ACF} . No que diz respeito aos demais atributos, serão apresentados apenas os resultados finais (IIQ^L ou M_d^L).

Na Tabela 10, são rerepresentadas as faixas de valores dos hiperparâmetros que foram investigadas no processo de definição dos limiares dos cinco atributos. Essas faixas foram fixadas conforme descrito no Apêndice C.3.

As configurações de parâmetros com os melhores desempenhos, no caso do atributo $\rho_{xx}(\eta)$, são apresentadas na Tabela 11, conjuntamente aos respectivos valores de FPR e AUC obtidos. A análise dessa tabela mostra que os melhores resultados ($FPR \leq 10\%$) foram atingidos para as configurações de parâmetros com valor de $FD = 0,6$ e $\lambda_2 = -0,94$, enquanto os demais parâmetros têm valores nas faixas $200 \leq \eta_{max} \leq 300$; $0,5 \leq OL \leq 0,8$ e $2350 \leq WS \leq 3420$. Para essas configurações, obteve-se os menores valores de FPR ($7,62 \leq FPR \leq 9,52$). A configuração que apresentou o melhor desempenho é mostrada em destaque na Tabela 11, tendo sido obtidos o valor mínimo de $FPR = 7,62\%$ e o valor máximo de $AUC = 94,4\%$. A partir do ponto de operação da curva ROC associada a essa configuração de hiperparâmetros, obteve-se o limiar de classificação IIQ^{ACF} para o atributo $\rho_{xx}(\eta)$ (coeficiente ACF).

A Tabela 12 apresenta os valores dos hiperparâmetros utilizados na definição dos limiares de classificação para os cinco atributos. São indicados os valores do FPR e AUC obtidos com cada uma das configurações de parâmetros. Na Figura 43 são apresentadas as curvas ROC dos cinco atributos, obtidas a partir dessas configurações de hiperparâmetros.

Tabela 10 – Faixas de valores dos hiperparâmetros utilizadas no processo de definição dos limiares de classificação. São válidas para os cinco atributos.


FD	η_{max}	λ_2	OL	WS
[0,5:0,1:0,9]	[100:50:450]	[-2:1:2]	[0:0,1:0,9]	[500:10:4000]

Tabela 11 – Configurações de hiperparâmetros que proporcionaram os melhores desempenhos, no caso do atributo $\rho_{xx}(\eta)$. Em destaque de cor, é indicada a melhor configuração, com os respectivos valores de FPR e AUC obtidos.

FD	0,6	0,6	0,6	0,6	0,6	0,6	0,6	0,6	0,6	0,6	0,6	0,6
η_{max}	200	200	200	200	250	250	250	250	300	300	300	300
λ_2	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94	-0,94
OL	0,5	0,6	0,7	0,8	0,5	0,6	0,7	0,8	0,5	0,6	0,7	0,8
WS	1024	2410	2410	2350	2740	2950	2350	2350	2700	3420	3430	2320
FPR [%]	12,38	8,57	8,57	7,62	7,62	8,57	7,62	9,52	9,52	9,52	10,48	10,48
AUC [%]	93,7	92,4	92,2	93,3	93,4	93,3	94,4	94,1	93,6	94,5	94,0	94,0

Tabela 12 – Configurações de hiperparâmetros que propiciaram o melhor desempenho dos cinco atributos.

Atributo	FD	η_{max}	λ_2	OL	WS	FPR[%]	AUC [%]
IIQ ^{ACF}	0,6	250	-0,94	0,7	2350	7,62	94,4
IIQ ^{PE}	0,6	-	1,22	0,5	2048	67,62	74,3
IIQ ^{SE}	0,6	-	1,30	0,7	2048	51,43	80,3
M _d ^{PR}	0,6	-	0	0,7	2048	76,19	59,2
M _d ^{MI}	0,6	-	-0,70	0	1024	65,71	64,2

Figura 43 – Curvas ROC dos cinco atributos para as configurações de hiperparâmetros da Tabela 12. Em cada curva é indicado o ponto ótimo de operação, com o valor de TFP correspondente a TVP = 90%.


4.3.2 Seleção do classificador FDA

Nesta seção são apresentados os resultados da análise comparativa (Seção 3.5.3), que culminou na escolha do classificador FDA com melhor desempenho. Tendo em vista a maior discriminação do atributo ACF, quando usado individualmente, a avaliação de desempenho dos dois classificadores (FDA e SVM), utilizando as várias combinações dos atributos (em grupos de 2, 3, 4 ou 5) foi limitada às 15 combinações que incluem esse atributo (vide Figura 45d).

Na Figura 44, são apresentados os *boxplots* das distribuições de valores médios obtidos na avaliação dos parâmetros de desempenho, utilizando-se a combinação de atributos {ACF, PE, SE, PR, MI}, associada a cada uma das duas opções do hiperparâmetro *DiscrimType* (linear e quadrática, vide Tabela 4). A análise dos gráficos revela que, de um modo geral, o desempenho do classificador FDA, utilizando o *DiscrimType* quadrático, superou o do *DiscrimType* linear para todos os parâmetros de desempenho avaliados. No caso da acurácia ACC (Figura 44a), o valor mediano do *DiscrimType* quadrático supera o do *DiscrimType* linear em 7%. Nos casos da TVP (Figura 44b) e da AUC (Figura 44d), o desempenho do *DiscrimType* quadrático supera o do linear em mais de 13% e 3%, respectivamente. No caso da TFP (Figura 44c), obteve-se o mesmo resultado mediano (8,4%) para as duas opções de *DiscrimType* (linear e quadrática). Os resultados obtidos para as duas opções são estatisticamente diferentes com relação à ACC, TVP

e AUC, sendo aproximadamente equivalentes no caso da TFP.

Figura 44 – *Boxplots* das distribuições de valores dos parâmetros de desempenho para a combinação de atributos {ACF, PE, SE, PR, MI}, com os *DiscrimType* linear e quadrático. São indicados os valores medianos: (a) Acurácia (ACC), (b) TVP, (c) TFP e (d) AUC.




Na Figura 45, são apresentados os *boxplots* conjuntos das distribuições dos valores médios dos quatro parâmetros de desempenho, avaliados para cada uma das 15 combinações de atributos. Nesse caso, usou-se o *DiscrimType* quadrático, escolhido como o de melhor desempenho na análise comparativa anterior. Tendo como base os resultados da Figura 45, apresentamos a seguir as conclusões que levaram à escolha do classificador FDA:

1. Inicialmente, foram selecionadas as combinações de atributos que apresentaram os quatro parâmetros de desempenho com mediana da distribuição de valores dentro das seguintes faixas: $ACC \geq 85\%$ (Figura 45a), $TVP \geq 76\%$ (Figura 45b), $TFP \leq 6\%$ (Figura 45c) e $AUC \geq 95\%$ (Figura 45d). Na Figura 45, são indicadas apenas as medianas situadas nessas faixas de valores. As combinações que atendem a esse critério de seleção descrito são {ACF, SE}, {ACF, SE, PR} e {ACF, SE, MI};
2. Comparando as medianas das distribuições dos parâmetros de desempenho para as três combinações (Figuras 45a a 45d), observa-se que apresentam valores iguais para a acurácia (85%) e para a TFP (5,3%). No entanto, a combinação {ACF, SE} apresenta um valor de TVP (76,7%) um pouco maior que os das combinações {ACF, SE, PR} e {ACF, SE, MI} (ambas iguais a 76,2%). Por outro lado, no que tange à AUC, o desempenho da combinação {ACF, SE, PR} (96,7%) supera o da {ACF, SE, MI} (95,9%) e o da {ACF, SE} (95,5%). Os resultados obtidos para as três combinações são estatisticamente diferentes apenas no que se refere à AUC, sendo aproximadamente equivalentes nos casos da ACC, TVP e TFP.
3. Considerando-se que um maior valor da TVP indica uma maior probabilidade de detecção dos componentes de frequência do sinal analisado uma vez que, nesse caso, é maior a chance de que IMF-Ts sejam classificadas corretamente, optou-se em utilizar esse parâmetro de desempenho para nortear a escolha da combinação de atributos com melhor desempenho,

entre as três selecionadas no item 1 ($\{ACF, SE\}$, $\{ACF, SE, PR\}$ e $\{ACF, SE, MI\}$). Portanto, a combinação $\{ACF, SE\}$ foi a escolhida.

Concluindo, o classificador FDA que apresentou o melhor desempenho foi aquele treinado e validado com o *DiscrimType* quadrático e a combinação de atributos $\{ACF, SE\}$.

Figura 45 – *Boxplots* das distribuições de valores médios dos parâmetros de desempenho para as várias combinações de atributos, com o *DiscrimType* quadrático: (a) Acurácia (ACC), (b) TVP, (c) TFP e (d) AUC.



4.3.3 Seleção do classificador SVM

Nesta Seção são apresentados os resultados obtidos no processo de seleção do classificador SVM (Seção 3.5.3), que consiste na escolha da combinação de atributos e dos hiperparâmetros BC, KS e função *kernel*, com os quais o classificador atinge o seu melhor desempenho.

Após uma análise inicial com valores de BC e KS dentro de uma ampla faixa ($0,1 \leq BC \leq 10$, para ambos os casos), constatou-se uma visível saturação dos resultados obtidos na avaliação dos parâmetros de desempenho para valores de $BC \geq 7$ e para valores de $KS \geq 3$. Para valores de $KS < 0,1$ e de $BC < 1$, observou-se duas tendências dos resultados dessa avaliação: ou uma crescente degradação ou uma saturação. Assim sendo, restringiu-se a análise às faixas de valores indicadas na Tabela 13, em que estão especificados os hiperparâmetros utilizados no processo de escolha do classificador SVM.

Tabela 13 – Hiperparâmetros usados no treinamento e validação dos classificadores SVM.

Descrição	Parâmetros
Função <i>kernel</i>	linear, quadrática, cúbica e Gaussiana
BC	1, 3, 5 e 7
KS	0,1 : 0,1 : 3,0

Como resultado da aplicação do método apresentado na Seção 3.5.3, após a realização da VC utilizando todas as possíveis combinações de atributos e hiperparâmetros da Tabela 13, obteve-se 15 conjuntos de 12 curvas (4 curvas por gráfico) formadas com os valores medianos das distribuições dos três parâmetros de desempenho (ACC, TVP e TFP). Um desses conjuntos de curvas é mostrado na Figura 46, para uma das 15 possíveis combinações de atributos, associada aos 4 valores de BC (1, 3, 5 e 7), aos valores de KS (na faixa $[0,1 - 3,0]$) e à função *kernel* Gaussiana. Em cada gráfico, identificou-se o ponto de máximo (mínimo) correspondente ao melhor valor de um dos três parâmetros de desempenho, para uma dada combinação de atributos e hiperparâmetros.

Os valores de máximo (mínimo) dos três parâmetros de desempenho, identificados para as várias associações entre combinação de atributos e função *kernel*, são apresentados nas Tabelas 14 a 17, sendo indicados (em destaque de amarelo) os maiores (menores) entre todos eles. Tem-se, portanto, as seguintes associações selecionadas: {ACF, SE} Gaussiana, {ACF, PR} linear, {ACF, PR} quadrática, {ACF, PR} cúbica, {ACF, PR} Gaussiana, {ACF, MI} linear, {ACF, MI} quadrática, {ACF, MI} cúbica, {ACF, MI} Gaussiana, {ACF, PR, MI} linear, {ACF, PR, MI} quadrática e {ACF, PE, SE, PR, MI} Gaussiana.

Comparou-se, então, os valores dos três parâmetros de desempenho para as associações selecionadas. A seguir, são apresentados os resultados dessa comparação:

- A associação {ACF, SE} Gaussiana obteve o maior valor de ACC (94,0%), superando os valores obtidos por todas as demais associações selecionadas, que obtiveram valores na faixa $[86,0\% - 91,0\%]$. A associação {ACF, PE, SE, PR, MI} obteve o pior resultado com relação a esse parâmetro de desempenho ($ACC = 86,0\%$);
- A associação {ACF, SE} Gaussiana obteve o segundo maior valor de TVP (94,3%), sendo superada apenas pela associação {ACF, PE, SE, PR, MI} Gaussiana, que obteve $TVP = 98,8\%$. As demais associações apresentaram valores na faixa $[81,4\% - 87,6\%]$;

- As associações {ACF, PR} linear, {ACF, PR} quadrática, {ACF, PR} cúbica, {ACF, PR} Gaussiana, {ACF, MI} linear, {ACF, MI} quadrática, {ACF, MI} cúbica, {ACF, MI} Gaussiana, {ACF, PR, MI} linear e {ACF, PR, MI} quadrática apresentaram o melhor desempenho com relação à TFP (0,0%). O valor obtido pela associação ACF/SE Gaussiana (TFP = 4,2%) foi menor que o da associação {ACF, PE, SE, PR, MI} Gaussiana, que apresentou o pior desempenho com relação a esse parâmetro (TFP = 8,4%).

Por essa análise, a associação {ACF, SE} Gaussiana foi a que apresentou os melhores resultados com relação ao maior número de parâmetros de desempenho entre os três avaliados: a maior ACC (94,0%) e a segunda maior TVP (94,3%). Tem-se, portanto, que a combinação de atributos e a função *kernel* selecionadas são, respectivamente, a {ACF, SE} e a Gaussiana.

Por fim, foram escolhidos os valores de BC e KS, a partir dos gráficos de valores medianos das distribuições dos três parâmetros de desempenho da associação {ACF, SE} Gaussiana (Figura 46). Nesses gráficos, são indicados os pontos de máximo (mínimo), escolhidos de forma a se obter valores de BC e KS comuns aos três parâmetros de desempenho. Assim sendo, apesar do ponto de máximo da Figura 46b corresponder a TVP = 94,3% (BC = 7 e KS = 0,1), optou-se por TVP = 92,4% que, apesar de ser um valor menor, satisfaz à condição enunciada anteriormente, uma vez que os valores BC = 7 e KS = 0,5 são comuns aos pontos de máximo (mínimo) dos três gráficos.

Tem-se, portanto, que os valores dos hiperparâmetros escolhidos para o classificador SVM são BC = 7 e KS = 0,5, a função kernel Gaussiana e a combinação de atributos {ACF, SE}.

Tabela 14 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, PE}, {ACF, SE}, {ACF, PR} e {ACF, MI}.

Combinação de atributos		{ACF, PE}				{ACF, SE}				{ACF, PR}				{ACF, MI}			
Função <i>kernel</i>		Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana
Parâmetro de Desempenho	ACC max. (%)	90,5	89,3	89,5	89,3	91,5	89,7	93,0	94,0	90,5	90,0	91,0	88,5	89,5	89,0	89,5	86,5
	TVP max. (%)	85,7	84,2	86,7	88,6	88,6	86,7	91,4	94,3	85,7	84,3	87,6	83,8	85,7	84,8	86,7	81,4
	TFP min. (%)	2,1	3,2	3,2	3,2	4,2	4,2	5,3	4,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0

Tabela 15 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, PE, SE}, {ACF, PE, PR}, {ACF, PE, MI} e {ACF, SE, PR}.


Combinação de atributos		{ACF, PE, SE}				{ACF, PE, PR}				{ACF, PE, MI}				{ACF, SE, PR}			
Função <i>kernel</i>		Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana
Parâmetro de Desempenho	ACC max. (%)	90,5	89,5	90,8	88,5	91,0	89,5	89,3	89,3	90,0	90,5	90,5	87,5	89,3	89,3	92,5	89,7
	TVP max. (%)	87,6	85,7	89,5	90,5	85,7	83,8	86,7	86,9	85,7	86,7	87,6	90,4	87,6	85,7	91,4	92,5
	TFP min. (%)	5,3	5,8	5,8	6,3	3,2	4,2	4,3	5,3	3,2	3,2	3,2	6,3	4,2	5,3	5,3	5,3

Tabela 16 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, SE, MI}, {ACF, PR, MI}, {ACF, PE, SE, PR} e {ACF, PE, SE, MI}.

Combinação de atributos		{ACF, SE, MI}				{ACF, PR, MI}				{ACF, PE, SE, PR}				{ACF, PE, SE, MI}			
Função <i>kernel</i>		Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana
Parâmetro de Desempenho	ACC max. (%)	91,5	90,0	91,5	87,7	89,5	89,0	89,5	83,0	90,5	89,3	89,5	86,5	90,5	89,0	89,5	87,0
	TVP max. (%)	88,6	86,7	89,5	94,3	85,2	83,8	85,7	90,5	87,6	85,7	88,1	97,1	88,1	85,2	87,6	98,1
	TFP min. (%)	4,2	5,3	5,8	6,3	0,0	0,0	1,1	1,1	5,3	5,3	6,8	7,4	5,3	5,8	6,3	7,4

Tabela 17 – Valores medianos máximos/mínimos dos parâmetros de desempenho para as combinações de atributos {ACF, PE, PR, MI}, {ACF, SE, PR, MI} e {ACF, PE, SE, PR, MI}.

Combinação de atributos		{ACF, PE, PR, MI}				{ACF, SE, PR, MI}				{ACF, PE, SE, PR, MI}			
Função <i>kernel</i>		Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana	Linear	Quadrática	Cúbica	Gaussiana
Parâmetro de Desempenho	ACC max. (%)	90,0	89,5	87,5	84,5	91,0	89,0	89,5	85,0	90,5	87,3	87,0	86,0
	TVP max. (%)	85,7	85,2	83,8	98,1	87,6	86,2	88,6	97,1	87,6	83,8	84,8	98,8
	TFP min. (%)	3,2	5,8	6,3	6,3	4,2	6,3	6,3	6,3	5,3	7,4	8,4	8,4

Figura 46 – Curvas dos valores medianos das distribuições dos parâmetros de desempenho, obtidos para a combinação de atributos {ACF, SE}. Os gráficos correspondem a 4 valores de BC (1, 3, 5 e 7), valores de KS (na faixa [0,1 – 3,0] e à função *kernel* Gaussiana. São indicados os valores dos parâmetros com melhor desempenho (máximos ou mínimos): (a) ACC; (b) TVP e (c) TFP.

4.3.4 Análise e comparação dos classificadores SVM e FDA

Uma vez obtidos o conjunto de hiperparâmetros e a combinação de atributos dos classificadores FDA e SVM (Seções 4.3.2 e 4.3.3, respectivamente), procedeu-se a análise e comparação entre os desempenhos dos dois classificadores. Além disso, comparou-se os desempenhos dos classificadores com os dos atributos individuais. Com base nessa análise comparativa, foi escolhido o classificador de melhor desempenho para integrar o Seletor de IMFs do sistema proposto.

Visando facilitar essa comparação, as curvas ROCs obtidas para os dois classificadores e atributos individuais são apresentadas conjuntamente na Figura 47. Nessas curvas, são indicados os pontos ótimos de operação, com os respectivos valores de TFP correspondentes a TVP = 90%.

De modo semelhante, os boxplots conjuntos das distribuições de valores dos parâmetros de desempenho (ACC, TVP, TFP e AUC) são apresentados nas Figuras 48 e 49, com a indicação das respectivas medianas, no caso dos classificadores FDA e SVM. Além disso, também é indicado o valor máximo (mínimo) desses parâmetros, relativo ao classificador com melhor desempenho.

A seguir, são analisados os principais resultados mostrados nessas figuras:

- A Figura 47 mostra o melhor desempenho do classificador SVM em relação ao FDA e a todos os atributos individuais. Por essa figura, observa-se que, para TVP = 90% (valor adotado como critério de eficiência), o TFP do SVM (2,1%) é 10,4% menor que o do FDA (12,5%). Por outro lado, ao combinar-se os atributos individuais ACF e SE, houve uma redução de 6,3% do TFP do classificador SVM em relação ao TFP do ACF individualmente (8,4%). Em relação ao TFP do SE (41,1%), a redução é ainda maior (39%);
- A análise das distribuições de valores dos parâmetros de desempenho (Figuras 48 e 49 e Tabela 19), mostra que o classificador SVM obteve melhores resultados do que o FDA para todos eles: a ACC mediana é 9% maior (Figura 48a), a TVP mediana é 16,2% maior (Figura 48b), a TFP mediana é 1,1% menor (Figura 49a) e a AUC mediana é 1,9% maior (Figura 49b);
- Essas distribuições de valores também mostram que, na maioria dos casos, o classificador SVM apresentou melhor desempenho ao combinar os atributos individuais ACF e SE. No caso da ACC média (Figura 48a), houve um aumento de 4% do valor apresentado pelo SVM (94%) em relação ao valor do ACF (90%) e 17,5% em relação ao valor do SE (76,5%);
- No caso do TVP médio (Figura 48b), houve um aumento de 7,6% do valor apresentado pelo SVM (92,4%) em relação ao apresentado pelo ACF e pelo SE (84,8% nos dois casos);
- No caso do TFP médio (Figura 49a), não houve melhoria de desempenho com a combinação dos atributos ACF e SE. Apesar do classificador SVM apresentar um valor deste parâmetro (4,2%) bem menor que o do SE (32,6%), não houve melhoria em relação ao ACF, que também apresentou TFP = 4,2%;
- Finalmente, o classificador SVM apresentou AUC média (Figura 49b) igual a 97,8%, um valor cerca de 1% maior do que o do ACF (96,9%) e 14% maior que o do SE (83,8%);
- Os resultados obtidos para os cinco atributos individuais e dois classificadores são estatisticamente diferentes no que se refere à ACC, TFP e AUC, sendo aproximadamente equivalentes para os os cinco atributos, no caso da TVP.

Como conclusão geral, o classificador SVM foi o selecionado para integrar o Seletor de IMFs do sistema proposto. Um resumo das características operacionais e valores dos parâmetros de desempenho do classificador SVM com melhor desempenho é apresentado na Tabela 18.

Tabela 18 – Conjunto de valores dos Hiperparâmetros do classificador SVM selecionado, juntamente com os valores obtidos dos parâmetros de desempenho.

Função <i>kernel</i>	Nível de restrição (BC)	Escala de <i>kernel</i> (KS)	Combinação de atributos	ACC max (%)	TVP max (%)	TFP min (%)	AUC max (%)
Gaussiana	7	0,5	{ACF, SE}	95,0	94,3	3,2	97,8

Tabela 19 – Valores dos parâmetros de desempenho das distribuições mostradas nas Figuras 48 e 49: mediana (em vermelho) e IIQ (em azul)

	ACF	PE	SE	PR	MI	FDA	SVM
ACC	90,0	68,0	76,5	58,5	62,5	85,0	95,0
(%)	1,0	1,5	0,5	1,5	0,5	0,5	1,5
TVP	84,8	84,8	84,8	85,2	83,8	76,2	92,4
(%)	1,9	1,0	1,0	0,9	1,0	1,0	1,6
TFP	4,2	50,5	32,6	71,1	62,1	5,3	4,2
(%)	1,1	2,1	1,1	2,1	0,0	0,0	0,0
AUC	96,9	76,5	83,8	57,1	62,5	95,9	97,9
(%)	0,0	0,0	0,0	0,0	0,0	0,0	0,0

Figura 47 – Curvas ROC dos classificadores SVM e FDA e dos cinco atributos individuais. Em cada curva é indicado o ponto ótimo de operação, com o valor de TFP correspondente a TVP = 90%.




Figura 48 – Distribuições de valores da ACC e TVP dos classificadores SVM e FDA e dos atributos individuais, com indicação dos valores medianos (SVM e FDA) e máximo de cada atributo: (a) ACC e (b) TVP.





Figura 49 – Distribuições de valores da TFP e AUC dos classificadores SVM e FDA e dos atributos individuais, com detalhes em escala expandida e indicação dos valores máximo (mínimo): (a) TFP e (b) AUC.



4.3.5 Avaliação do EMD-IRNI em operação

Nesta seção são apresentados os resultados da avaliação de desempenho do sistema proposto EMD-IRNI, operando com o classificador SVM selecionado (Tabela 18). A avaliação seguiu o método apresentado na Seção 3.5.3.

Operação com sinais experimentais

Após o processamento do conjunto de sinais experimentais pelo sistema proposto (com a geração de 200 IMFs), realizou-se a comparação entre as classes reais (IMF-T ou IMF-R) indicadas no gabarito construído pelo especialista (Tabela 24 do Apêndice D), com os respectivos resultados da classificação realizada pelo Seletor de IMFs. Nessa comparação, foi verificada a ocorrência de 10 erros de classificação, falsos positivos (FP) ou falsos negativos (FN). A seguir, é feita uma descrição dos 10 erros ocorridos:

- Quatro erros na classificação de IMFs relativas aos sinais 19, 33, 35 e 36. Pelo gabarito, são IMFs pertencentes à classe das IMF-R, mas que foram classificadas erradamente pelo seletor de IMFs como IMF-T. Portanto, o número de falsos positivos é igual a $FP = 4$;
- Seis erros na classificação de IMF relativas aos sinais 6, 9, 14, 15, 29 e 38. Pelo gabarito, são IMFs pertencentes à classe das IMF-T, mas que foram classificadas erradamente pelo seletor de IMFs como IMF-R. Portanto, o número de falsos negativos é igual a $FN = 6$.

Considerando-se que, de acordo com o gabarito, existe um total de 105 IMF-T e 95 IMF-R no conjunto de 200 IMFs analisadas, conclui-se que o número de verdadeiros positivos é igual a $VP = 105 - FN = 105 - 6 = 99$ e o número de verdadeiros negativos é igual a $VN = 95 - FP = 95 - 4 = 91$. A partir desses erros contabilizados, são calculados os valores dos parâmetros de desempenho TVP, TFP e ACC (Tabela 2):

$$TVP = \frac{VP}{VP + FN} \times 100\% = \frac{99}{99 + 6} \times 100\% \cong 94,3\% \quad (4.2)$$

$$TFP = \frac{FP}{FP + VN} \times 100\% = \frac{4}{4 + 91} \times 100\% \cong 4,2\% \quad (4.3)$$

$$ACC = \frac{VP + VN}{VP + VN + FP + FN} \times 100\% = \frac{99 + 91}{99 + 91 + 4 + 6} \times 100\% \cong 95,0\% \quad (4.4)$$

Comparando esses resultados com aqueles obtidos na seleção do classificador SVM (Tabela 18), constatou-se que, à exceção do TFP (no presente cálculo, apresentando um valor 1% maior), os valores dos demais parâmetros de desempenho são praticamente os mesmos.

Visando facilitar a apresentação, mostramos nas Figuras 50 e 51 os resultados das etapas de processamento de dois dos 10 sinais (sinais 6 e 33, da Tabela 24), nos quais ocorreu algum erro de classificação (FN e FP, respectivamente). As conclusões apresentadas a seguir, com base nesses dois sinais específicos, serão, na sequência, generalizadas para os demais.

Nas Figuras 50a e 51a, são mostradas as 5 IMF_i resultantes da decomposição UPEMD no seletor de IMFs (Figura 23), que são entradas do classificador. Nas Figuras 50b e 51b, são mostrados os resultados da classificação dessas 5 IMF_i, que podem ser IMF-T ou IMF-R. Nos casos de erro de classificação, também é indicado nessas figuras o tipo do erro (FN ou FP). Nas Figuras 50c e 51c, é apresentada a PSD média normalizada $\bar{P}(f)$ resultante da aplicação da análise DEMON aos dois sinais, com a indicação do NMR e do limiar de seleção y_{LIM} (Apêndice D). Por fim, nas Figuras 50d e 51d exibimos o MHS resultante do processamento EMD-IRNI aplicado aos sinais, com a indicação do NMR.

A análise da Figura 50c (relativa ao sinal 6) indica que os componentes-referência (definidos no Apêndice D), com amplitudes relativamente maiores que o limiar de seleção y_{LIM} , são detectados em algumas das 5 IMF_i (Figura 50a). Esse é o caso do componente de frequência 1888 rpm (componente-referência 1885 rpm), detectado na IMF1, do componente 1258 rpm (componente-referência 1260 rpm), detectado na IMF2, dos componentes 588,7 rpm e 629,5 rpm (componentes-referência 586 rpm e 630 rpm, respectivamente), ambos detectados na IMF3.


No entanto, para esse sinal, a IMF1 foi classificada erroneamente como IMF-R e descartada pelo seletor de IMFs (Figura 50b), o que caracteriza um FN. Como a IMF1 foi descartada, o componente 1888 rpm não aparece no MHS (Figura 50d). Por outro lado, a IMF2 e a IMF3 foram classificadas corretamente como IMF-T pelo seletor de IMFs, aparecendo no MHS (componentes 1257 rpm e 628,5 rpm, respectivamente, na Figura 50d). A razão dessa diferença na classificação pelo seletor de IMFs se deve, provavelmente, ao maior nível de ruído incidente na IMF1, em comparação à IMF2 e IMF3.

Os componentes-referência 1216 rpm e 1698 rpm (Figura 50c), apesar de detectados nas IMF1 e IMF3 (Figura 50a), respectivamente, quase se confundem com a banda de ruído dessas IMFs, provavelmente por serem componentes de baixa amplitude, muito próximos do limiar de seleção y_{LIM} (Figura 50c).

Quanto ao componente-referência 586 rpm (Figura 50c), por possuir uma amplitude relativamente maior ($\sim 4,3$ dB) que a dos dois componentes anteriores (portanto mais distanciado do limiar de seleção), foi detectado na IMF3 (588,7 rpm, na Figura 50a). No entanto, esse componente é muito próximo do componente de frequência 630 rpm (Figura 50c) que, por ter uma amplitude quase 7 dB maior, acabou por se sobrepor ao primeiro. Provavelmente por essa razão, o componente 586 rpm não aparece no MHS (Figura 50d).

Finalmente, as IMF4 e IMF5 (Figura 50a), pertencentes à classe das IMF-R (Tabela 24), são corretamente classificadas como IMF-R e descartadas pelo seletor de IMFs (Figura 50b), o que contribui para a diminuição de ruído no MHS (Figura 50d).

Figura 50 — Resultados do processamento pelo EMD-IRNI do sinal 6: (a) Entradas do seletor de IMFs, (b) Saídas do seletor de IMFs, (c) PSD média normalizada $\bar{P}(f)$ (análise DEMON) e (d) MHS.




A análise da Figura 51 (relativa ao sinal 33), revela que se trata de um sinal bem menos ruidoso em comparação ao sinal 6, por apresentar IMFs com bandas de ruído mais estreitas (Figura 51a) e $\bar{P}(f)$ com NMR aproximadamente 15 dB inferior (Figura 51c). Em razão disso, todos os componentes-referência estão acima do limiar de seleção y_{LIM} . A maioria deles (1157 rpm, 1178 rpm, 386,7 rpm, 392,6 rpm e 96,7 rpm, na Figura 51c) é detectada pelas IMF1 (1158 rpm e 1179 rpm), IMF2 e IMF3 (ambas 385,9 e 393,2 rpm) e IMF5 (96,5 e 98,3 rpm), respectivamente. Por atenderem aos quatro critérios do especialista (Apêndice D), são classificadas como IMF-T (Tabela 24). Como foram classificadas corretamente pelo seletor de IMFs, esses três componentes aparecem no MHS (Figura 51d). O componente-referência 471,7 rpm, apesar de relativamente distante dos demais componentes, não aparece em nenhuma IMF e, conseqüentemente, também não aparece no MHS. É importante ressaltar que, apesar de muito próximos entre si, os componentes-referência 386,7 rpm e 392,6 rpm conseguiram ser distinguidos e detectados pelo método proposto, o mesmo ocorrendo com os componentes-referência 1157 rpm e 1178 rpm, aparecendo, portanto, no MHS (Figura 51d).

A IMF4, por apresentar o componente-significativo (definido no Apêndice D) 248,2 rpm, ausente na PSD média normalizada $\bar{P}(f)$ (Figura 51c), não atende ao critério 4 do especialista (Apêndice D), tendo sido classificada como IMF-R (Tabela 24). No entanto, foi classificada incorretamente como IMF-T pelo seletor de IMFs (Figura 51b). Temos, portanto, um caso de FP.

Como consequência, esse componente aparece incorretamente no MHS (247,2 rpm, na Fig.51d).

Figura 51 – Resultados do processamento pelo EMD-IRNI do sinal 33: (a) Entradas do seletor de IMFs, (b) Saídas do seletor de IMFs, (c) PSD média normalizada $\bar{P}(f)$ (análise DEMON) e (d) MHS.



Como conclusão geral da análise, foi possível identificar três possíveis cenários associados aos 10 erros de classificação:

- componentes-referência da PSD média normalizada $\bar{P}(f)$ com baixa amplitude, relativamente próxima do limiar de seleção γ_{LIM} , que não conseguiram ser detectados por nenhuma IMF, não aparecendo, portanto, no MHS;
- IMFs classificadas como IMF-T pelo especialista, que foram erroneamente classificadas como IMF-R pelo seletor de IMFs, muito provavelmente em razão da alta incidência de ruído. Nesse caso, ocorreu um erro de FN;
- IMFs classificadas como IMF-R pelo especialista, por não apresentarem componentes-significativos com frequência dentro da faixa de interesse da $\bar{P}(f)$, não atendendo, portanto, os critérios 3 e 4. No entanto, essas IMFs foram classificadas erroneamente como IMF-T pelo seletor de IMFs, o que configura um erro de FP.

Uma possível explicação para o primeiro tipo de erro é a limitação do método de decomposição EMD utilizado no seletor de IMFs (UPEMD) em detectar componentes de baixa amplitude, que compartilham a mesma banda com o ruído, no sinal pré-processado $x[n]$ (Figura 23), a exemplo do sinal 6. Ou seja, a limitada robustez ao ruído da UPEMD.

Com relação ao segundo tipo de erro, é possível avaliar a influência do ruído incidente no desempenho do seletor de IMFs, analisando os resultados obtidos com o processamento do sinal 6 (Figura 50a). Neste caso, a IMF1 (bastante ruidosa), apesar de conter o componente-significativo de 1888 rpm, foi classificada erroneamente como IMF-R (FN). Essa falha de classificação, provavelmente é originada no processo de extração do atributo IIQ^{ACF} nas cinco IMFs (Seção 3.5.2).

Na Figura 52a, é mostrada a distribuição de valores da mediana ACF^5 nas cinco IMF_i , obtidas pela aplicação do EMD-IRNI ao sinal 6. Confrontando as Figuras 50a e 52a, pode-se notar que os valores de IIQ^{ACF} das IMF_i são diretamente proporcionais às respectivas SNR_i , $i = 1, 2, \dots, 5$ (Equação (3.5)). Os valores de SNR_i e IIQ^{ACF} das IMF_i com erros de classificação são apresentados nas Tabelas 20 e 21, em que “R” indica a presença de ruído puro.

A relação de aproximada proporcionalidade entre SNR_i e IIQ^{ACF} é teoricamente compreensível, pela própria definição do coeficiente ACF ($\rho_{xx}(\eta)$, na Seção 3.5.2), a partir do qual se define IIQ^{ACF} (item 5 da Seção 3.5.2). Para os sinais com certa regularidade (contendo componentes-significativos), tem-se que $0 < |\rho_{xx}(\eta)| < 1$, com η variando em uma determinada faixa de valores. Quanto maior a regularidade, mais ampla é essa faixa, e maior a tendência dos valores de $|\rho_{xx}(\eta)|$ serem mais próximos de 1, indicando uma forte correlação entre o sinal e sua versão defasada de η amostras. Como IIQ^{ACF} representa a dispersão em torno da mediana da distribuição dos valores de $|\rho_{xx}(\eta)|$ (Seção 3.5.2), maior será o valor desse atributo em sinais menos ruidosos, que apresentam um padrão mais regular de comportamento. Já os sinais com baixa SNR ou ruído puro, apresentam $|\rho_{xx}(\eta)| \cong 0$ para valores de $\eta \neq 0$ e, portanto, $IIQ^{ACF} \cong 0$.

Portanto, no exemplo do sinal 6, as duas IMFs com maior SNR_i são a IMF3, seguida pela IMF2 (28,0 dB e 18,9 dB, respectivamente), que também apresentam os maiores valores de IIQ^{ACF} (0,287 e 0,090, respectivamente). No caso dessas duas IMFs, o atributo IIQ^{ACF} consegue detectar a regularidade existente nos componentes-significativos de 629,5 rpm e 1258 rpm.

Por outro lado, a IMF1 (Figura 50a), visivelmente mais ruidosa e com SNR_i (10,3 dB) menor que as da IMF2 e IMF3, apresenta $IIQ^{ACF} = 0,025$ (Tabela 20), um valor cerca de 4 e 11 vezes menor, respectivamente. Provavelmente por essa razão, o atributo IIQ^{ACF} não consegue detectar a regularidade do componente-significativo de 1888 rpm, presente nessa IMF. Nesse caso, o valor de $IIQ^{ACF} \cong 0$ apresentado indica incorretamente a ausência de regularidade na IMF1, razão pela qual o seletor de IMFs a classifica como IMF-R (FN). Portanto, nesse caso específico, o erro de classificação provavelmente se deve ao limite da robustez ao ruído na extração do atributo IIQ^{ACF} .

Quanto às IMF4 e IMF5 (Figura 50a), são IMFs visivelmente da classe das IMF-R, dada a ausência de componentes-significativos. Assim sendo, os valores mais baixos de IIQ^{ACF} (0,022 e 0,018, respectivamente, na Tabela 20), em comparação aos das demais, refletem corretamente a ausência de regularidade nessas duas IMFs.

Para compreender uma das possíveis causas do terceiro tipo de erro de classificação (FP), considere-se o exemplo do sinal 33 (Figura 51a). Como foi dito, apesar de possuir um componente-significativo (248,2 rpm), a IMF4 desse sinal foi classificada como IMF-R pelo especialista (Tabela 24), por não atender ao critério 4 (Apêndice D). Como é mostrado na Tabela 21 (e na Figura 52b), a IMF4 é a mais ruidosa entre as cinco IMF_i , apresentando $SNR_i = 11,4$ dB, um valor de 5 dB a 18 dB menor que o das demais. Isso se reflete no valor de IIQ^{ACF} que, no caso da IMF4 (0,020), é cerca de 5 a 25 vezes menor em relação aos das demais IMFs. Além disso, esse valor é menor que o apresentado pela IMF4 do sinal 6 ($IIQ^{ACF} = 0,022$, na Tabela 20), que foi corretamente classificada como IMF-R pelo seletor de IMFs, por conter apenas

⁵ Definida como $\text{med}^{i,\eta}$ no item 3 da Seção 3.5.2.

ruído, sem componentes -significativos. Entretanto, no caso do sinal 33, a IMF4 foi classificada como IMF-T, independentemente de possuir um menor valor de IIQ^{ACF} . Portanto, o erro de classificação foi, provavelmente, do seletor de IMFs.


Tabela 20 – Valores da SNR_i e de IIQ^{ACF} das cinco IMF_i , ($i = 1, 2, \dots, 5$) dos sinais 6, 9, 14, 15 e 19.

i	Sinal 6		Sinal 9		Sinal 14		Sinal 15		Sinal 19	
	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}
1	10,3	0,025	8,0	0,023	13,8	0,119	16,1	0,062	8,2	0,029
2	18,9	0,090	R	0,028	22,3	0,377	10,5	0,021	24,9	0,239
3	28,0	0,287	18,2	0,127	25,6	0,214	15,5	0,045	17,8	0,042
4	R	0,022	21,9	0,170	R	0,029	15,6	0,032	15,2	0,022
5	R	0,018	R	0,015	19,4	0,015	16,1	0,018	R	0,021

Tabela 21 – Valores da SNR_i e de IIQ^{ACF} das cinco IMF_i , ($i = 1, 2, \dots, 5$) dos sinais 29, 33, 35, 36 e 38.

i	Sinal 29		Sinal 33		Sinal 35		Sinal 36		Sinal 38	
	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}	SNR_i [dB]	IIQ^{ACF}
1	R	0,011	16,7	0,092	R	0,021	16,3	0,033	8,9	0,034
2	15,1	0,020	29,0	0,503	R	0,015	16,0	0,040	12,8	0,047
3	15,8	0,021	26,6	0,262	17,0	0,028	22,0	0,039	13,1	0,039
4	14,9	0,016	11,4	0,020	R	0,021	15,9	0,021	14,7	0,035
5	23,5	0,041	26,4	0,098	20,4	0,021	17,1	0,017	R	0,016

Figura 52 – Distribuições de valores da mediana ACF, obtidos no processamento, pelo EMD-IRNI, de dois entre os 10 sinais experimentais, em que ocorreram erros de classificação: (a) Sinal 6 e (b) Sinal 33.



Uma vez realizada a investigação sobre os três cenários que possivelmente determinaram a ocorrência dos 10 erros de classificação, nos casos específicos dos sinais 6 e 33, são apresentadas a seguir, conclusões mais gerais envolvendo todo o conjunto de 40 sinais experimentais, utilizado no processamento pelo EMD-IRNI.

Uma análise do gabarito especialista (Tabela 24) mostra que $\sim 77\%$ do conjunto total das IMF-T relativas aos 40 sinais experimentais se concentra nas três primeiras IMFs, enquanto

$\sim 60\%$ do total de IMF-R está nas duas últimas. Portanto, é compreensível que a maioria dos erros de classificação do tipo FN ($\sim 67\%$) tenha ocorrido nas duas primeiras IMFs (Tabela 24) que, juntamente com a IMF3, são majoritariamente da classe das IMF-T. Por outro lado, todos os erros do tipo FP ocorreram na IMF4, que predomina, com a IMF5, na classe das IMF-R.

No primeiro caso, 75% dos erros do tipo FN ocorreram na IMF1, que apresenta, para a maioria dos 10 sinais das Tabelas 20 e 21, os menores valores de SNR_i (entre 8,0 dB e 10,3 dB) e de IIQ^{ACF} (entre 0,011 e 0,119). No caso da IMF2, apesar da ocorrência de um erro do tipo FN com o sinal 15, essa IMF apresentou, para a maioria dos 10 sinais, valores relativamente maiores de SNR_i (entre 10,5 dB e 29,0 dB), como também de IIQ^{ACF} (entre 0,015 e 0,503). No caso específico do sinal 15, a IMF2 é muito ruidosa, com valores baixos de SNR_i (10,5 dB) e de IIQ^{ACF} (0,021), o que provavelmente influenciou na ocorrência do erro de classificação. Por outro lado, a IMF3 não apresentou nenhum erro de classificação, possuindo valores mais elevados de SNR_i (entre 13,1 dB e 28,0 dB) e de IIQ^{ACF} (entre 0,021 e 0,287), em comparação aos da IMF1.

No segundo caso, a ocorrência de erros de classificação do tipo FP na IMF4 de 4 dos 10 sinais (Tabelas 20 e 21), pode ser explicada pelo fato de que, juntamente com a IMF5, apesar de serem geralmente classificadas, pelo especialista, como IMF-R (por não possuírem componentes-significativos na faixa de interesse), em alguns casos podem conter componentes de frequência que são detectados pelo atributo IIQ^{ACF} . Consequentemente, são classificadas erroneamente como IMF-T pelo Seletor de IMFs.

Comparação de desempenhos nas operações com sinais experimentais e simulados


Na Figura 53, são apresentados os resultados da aplicação do EMD-IRNI ao conjunto de 40 sinais experimentais e à sua versão simulada (Seção 3.1.2), em que fixou-se $NMR \approx -30$ dB para cada sinal. O objetivo desse ensaio foi avaliar a influência do nível de ruído incidente no desempenho de detecção e estimação da frequência dos componentes espectrais pelo sistema proposto. Nesse sentido, comparando as distribuições das taxas de detecção relativas aos sinais simulados e aos experimentais (Figura 53a), é evidente o melhor desempenho alcançado pelo método proposto no primeiro caso, em que houve um aumento de 30% do valor mediano, com a diminuição do NMR nas versões simuladas dos 40 sinais experimentais.

Quanto à acurácia de estimação da frequência dos componentes detetados, as distribuições de $\overline{\Delta F}_p$ ilustradas na Figura 53b, também indicam um melhor desempenho do EMD-IRNI, no caso dos sinais simulados, por apresentar um valor mediano de $\overline{\Delta F}_p \approx 0,23\%$, um pouco menor que o obtido com os sinais experimentais ($\overline{\Delta F}_p = 0,27\%$). Além disso, a dispersão de valores em torno da mediana foi bem menor, no caso dos simulados (aproximadamente, $\pm 0,07\%$), obtendo-se um valor máximo de $\overline{\Delta F}_p \approx 0,30\%$. No caso dos experimentais a dispersão foi cerca de duas vezes maior ($\pm 0,15$), com um valor máximo de $\overline{\Delta F}_p \approx 0,50\%$. Um aspecto importante a se ressaltar é que o valor mediano de $\overline{\Delta F}_p$ é $\sim 38\%$ menor que o da análise DEMON padrão ($\overline{\Delta F}_p \approx 0,37\%$), aplicada ao mesmo conjunto de sinais simulados. Os resultados obtidos para os sinais experimentais e simulados são (do ponto de vista estatístico) aproximadamente equivalentes nas duas análises.

Portanto, foi mostrado nesse ensaio a importante influência do nível de ruído incidente

nos sinais experimentais de SONAR passivo, atuando como fator limitante da eficiência do EMD-IRNI, na detecção dos componentes harmônicos desses sinais. Ainda assim, os resultados obtidos pelo método proposto, aplicado aos sinais simulados, foram melhores do que os da análise DEMON padrão.

Figura 53 – Resultados da avaliação de eficiência de detecção do EMD-IRNI aplicado ao conjunto de 40 sinais experimentais e à sua versão simulada: (a) Taxa de detecção do EMD-IRNI; (b) Acurácia de estimação de frequência (ΔF_p) do EMD-IRNI e (c) Acurácia ΔF_p da análise DEMON padrão (simulados).



4.4 Análise comparativa entre os principais resultados dos três estudos de caso

No Estudo de Caso 1, realizou-se a comparação de desempenho da HHT-EMD, de suas principais variantes e da HHT-VMD. Entre os métodos investigados, a HHT-VMD, seguida pela HHT-UPEMD, obteve os melhores resultados na aplicação a sinais simulados e experimentais de SONAR passivo, com relação à resolução espectral (ΔF_{3dB}), acurácia de estimação de frequência (ΔF_p), robustez ao ruído ($\overline{SNR}$), resiliência à MM e comportamento dinâmico, inclusive superando a análise DEMON padrão. No entanto, ao ser comparada à HHT-UPEMD, a HHT-VMD mostrou ter uma maior sensibilidade ao ruído incidente em sinais experimentais de SONAR passivo, por falhar na detecção de um dos componentes de frequência. Portanto, apesar desses dois métodos se mostrarem viáveis para substituir a STFT na análise DEMON, evidenciou-se, ao final desse primeiro estudo, a necessidade de uma estratégia de redução de ruído.

Nesse sentido, realizou-se no Estudo de Caso 2 uma investigação preliminar, em que foi constatada a influência do ruído presente nas bandas compartilhadas entre os componentes espectrais de interesse das IMFs, bem como do próprio ruído, na degradação do HS e MHS, verificada no Estudo de Caso 1. Em seguida, foram avaliadas e escolhidas a HHT-VMD-BWTD e a HHT-UPEMD-BWTD, métodos em que a filtragem BWTD é aplicada às IMFs produzidas pela HHT-VMD e HHT-UPEMD, respectivamente. Entre os dois métodos selecionados, a HHT-VMD-BWTD foi o mais acurado, com melhor resolução espectral e que proporciona a maior redução de ruído nas bandas compartilhadas. Entretanto, tendo em vista a maior sensibilidade ao ruído

ambiental incidente em sinais experimentais de SONAR passivo, manifestada pela HHT-VMD no Estudo de Caso 1, além da HHT-VMD-BWTD, também foi selecionada a HHT-UPEMD-BWTD, para integrarem conjuntamente a EMD-IRNI, sistema proposto no Estudo de Caso 3.

No Estudo de Caso 3, foi realizada a implementação e avaliação do sistema inteligente EMD-IRNI, baseado no método de análise TF de sinais de SONAR passivo com redução de ruído, proposto na presente pesquisa. Nessa nova estratégia, as IMFs resultantes da decomposição UPEMD, são separadas em dois grupos por um classificador SVM: as IMF-T, que são tratadas pela BWTD para redução de ruído, e as IMF-R, que são descartadas. A classificação das IMFs é realizada com base na combinação dos atributos IIQ^{ACF} e IIQ^{SE} , extraídos das próprias IMFs analisadas. Entre as várias combinações dos cinco atributos investigados, essa foi aquela com a qual o EMD-IRNI apresentou o melhor desempenho: uma acurácia de 95% e TFP de 3,2%.

A escolha do atributo IIQ^{ACF} é uma consequência do melhor desempenho apresentado no processo de definição dos limiares de classificação. Entre todos os atributos investigados, foi o melhor discriminante entre as classes das IMF-T e IMF-R, o que se deve à sua característica específica de detectar padrões de regularidade em séries temporais, mostrando ser, portanto, o mais adequado para identificar componentes espectrais em sinais ruidosos de SONAR passivo.

Na análise realizada sobre as possíveis causas dos 10 erros de classificação, ocorridos na operação do EMD-IRNI com o conjunto de 40 sinais experimentais, verificou-se que, a maioria dos erros está relacionada ao ruído incidente. A conclusão da análise é que o ruído presente nas bandas compartilhadas com os componentes -significativos de frequência das IMFs, possivelmente influencie o desempenho do sistema, ao provocar eventuais falhas na detecção desses componentes, bem como na extração do atributo IIQ^{ACF} . Nesse último caso, o atributo não consegue detectar adequadamente os padrões de regularidade presentes nos componentes espectrais.

É importante ressaltar que a definição da estrutura e do posicionamento dos diversos blocos de processamento do sistema proposto (Figuras 22 e 23), seguiu algumas diretrizes, visando obter-se o melhor desempenho de cada um desses blocos individualmente, e do sistema global.

Considerando-se que o sinal pré-processado $x[n]$ (Figura 22) geralmente é bastante ruidoso (principalmente em se tratando de sinais experimentais), optou-se por utilizar a UPEMD como método de decomposição EMD desse sinal, tendo em vista a menor resiliência da VMD ao ruído incidente em sinais experimentais de SONAR passivo.

Nessa configuração, a eliminação das IMF-R pelo seletor de IMFs (Figura 22) e, em seguida, a filtragem BWTD das IMF-T selecionadas, proporcionaram uma redução significativa do nível de ruído e, consequentemente, o aumento da SNR das IMF-T_f (IMF-T filtradas). Após a reconstrução do sinal original com ruído reduzido, o sinal $x_{rec}[n]$ resultante é processado pela VMD. Nessa condição de operação com uma maior SNR, a VMD apresenta, na EMD-IRNI, um melhor desempenho, em comparação ao obtido pela HHT-VMD no Estudo de Caso 1 (Tabela 22).

No Estudo de caso 3, também foi realizado um ensaio sobre a influência do nível médio de ruído de fundo (NMR) dos sinais experimentais de SONAR passivo, em prejuízo da eficiência do método proposto, na detecção dos componentes de frequência desses sinais. Tendo em vista os melhores resultados obtidos com os sinais simulados, em comparação aos dos experimentais,

o valor de NMR ≈ -30 dB, fixado empiricamente nas simulações, poderá ser adotado como referência em futuras otimizações da estratégia de redução de ruído utilizada no sistema proposto.

Um resumo dos principais resultados obtidos pelos métodos com melhores desempenhos nos três estudos realizados nesta pesquisa, ao serem aplicados a um sinal experimental de SONAR passivo, é apresentado na Figura 54. Comparando as Figuras 54a, 54b e 54c, é visível o melhor desempenho da HHT-VMD-BWTD em relação à HHT-VMD e à DEMON padrão, desempenho esse obtido com a filtragem BWTD das IMF-T produzidas pela VMD. No primeiro caso, o HS e MHS apresentam linhas espectrais mais retilíneas e picos espectrais mais definidos, respectivamente. Na Figura 54d, são mostrados o HS e o MHS resultantes da aplicação da EMD-IRNI ao mesmo sinal anterior. Esses resultados são próximos aos obtidos pela HHT-VMD-BWTD, com exceção do componente de frequência ~ 148 rpm, que foi detectado pelo EMD-IRNI, muito provavelmente, por efeito da redução de ruído ocorrida com a eliminação das IMF-R pelo seletor de IMFs. O melhor desempenho da EMD-IRNI em relação HHT-VMD e à DEMON padrão é confirmado pelos parâmetros de desempenho da Tabela 22.

Tabela 22 – Medidas de desempenho dos métodos da pesquisa com melhores desempenhos no processamento do sinal experimental da Marinha do Brasil (conjunto 1). Os símbolos $\downarrow$ ($\uparrow$) indicam, respectivamente, que quanto menor (maior) for o valor do parâmetro, melhor é o desempenho do método.

Método	ΔF_p (%) $\downarrow$	SNR (dB) $\uparrow$	ΔF_{3dB} (rpm) $\downarrow$
DEMON	0,01	7,1	5,7
HHT-VMD	3,08	74,0	2,2
EMD-IRNI	0,16	94,9	0,2

Por fim, mostramos na Figura 55 e Tabela 23, os resultados dos métodos com melhor desempenho nos três estudos de caso, ao serem aplicados ao conjunto de 40 sinais experimentais e à sua versão simulada (fixando-se NMR ≈ -30 dB). Esse procedimento é semelhante ao realizado no ensaio do Estudo de Caso 3 (Seção 4.3.5), para a avaliação da influência do nível de ruído incidente no desempenho de detecção e estimação da frequência dos componentes espectrais pelo EMD-IRNI.

Pela análise da Figura 55a, que mostra as distribuições das taxas de detecção, é evidente o melhor desempenho dos três métodos, na aplicação aos sinais simulados, em comparação aos experimentais, ao apresentar um valor mediano ~ 30 pontos percentuais maior no caso dos simulados (Tabela 23). Na aplicação a sinais experimentais, apesar dos três métodos apresentarem o mesmo valor mediano (50,0%), a EMD-IRNI obteve um IIQ (45,0%) cerca de 18 pontos percentuais maior que a VMD-EXP e a VMD-BWTD-EXP, chegando a atingir valores acima de 80% (Tabela 23). Quanto à acurácia de estimação de frequência dos componentes detectados ($\overline{\Delta F_p}$, na Figura 55b e Tabela 23), apesar dos resultados dos vários métodos serem aproximadamente equivalentes (à exceção da VMD-EXP), é visível que são um pouco melhores na aplicação aos sinais simulados, em comparação aos experimentais.

Também é perceptível uma tendência à melhoria de desempenho com relação a $\overline{\Delta F_p}$, ao longo da sequência de realizações dos três estudos de caso, acompanhando o aperfeiçoamento crescente do método de análise. Assim sendo, o desempenho do EMD-IRNI-EXP, no Estudo de Caso 3 ($\overline{\Delta F_p} = 0,27\%$), é um pouco melhor que o do VMD-BWTD-EXP no Estudo de Caso 2

Figura 54 – Resultados dos métodos da pesquisa com melhores desempenhos, aplicados ao sinal experimental da Marinha do Brasil (conjunto 1), adquirido na Baía de Guanabara: (a) Análise DEMON (espectrograma à esquerda e $\bar{P}(f)$ à direita), (b) HHT-VMD (HS à esquerda e MHS à direita), c) HHT-VMD-BWTD (HS à esquerda e MHS à direita) e (d) EMD-IRNI (HS à esquerda e MHS à direita).




Figura 55 – Resultados da avaliação de eficiência de detecção dos métodos com melhor desempenho nos três estudos de caso e da DEMON padrão, quando aplicados ao conjunto de 40 sinais experimentais e à sua versão simulada: (a) Taxa de detecção; (b) Acurácia de estimação de frequência ($\overline{\Delta F_p}$).




Tabela 23 – Valor mediano e do IIQ das distribuições das taxas de detecção e das acurácias de estimação de frequência ($\overline{\Delta F_p}$) dos métodos, mostradas na Figura 55: mediana (em vermelho) e IIQ (em azul).

	VMD EXP	VMD-BWTD EXP	EMD-IRNI EXP	VMD SIM	VMD-BWTD SIM	EMD-IRNI SIM	DEMON
Taxa de deteção (%)	50,0 26,7	50,0 26,7	50,0 45,0	83,3 42,9	83,3 42,9	80,0 42,9	— —
$\overline{\Delta F_p}$ (%)	1,09 1,11	0,43 0,19	0,27 0,32	0,45 0,42	0,27 0,27	0,23 0,14	0,37 0,13

($\overline{\Delta F_p} = 0,43\%$), que é melhor que VMD-EXP no Estudo de Caso 1 ($\overline{\Delta F_p} = 1,09\%$). A mesma tendência é observada no caso dos sinais simulados: os valores de $\overline{\Delta F_p}$, obtidos por EMD-IRNI-SIM, VMD-BWTD-SIM e VMD-SIM são, respectivamente, 0,23%, 0,27% e 0,45%, sendo que os dois primeiros também foram melhores que o da DEMON padrão (0,37%). O pior desempenho da VMD-EXP, no que se refere à acurácia de estimação de frequência ($\overline{\Delta F_p}$), está em concordância com a maior sensibilidade da HHT-VMD a sinais experimentais de SONAR passivo, constatada no Estudo de Caso 1. No entanto, como mostram os resultados da VMD-BWTD-EXP e da EMD-IRNI-EXP (Tabela 23), houve uma melhoria de $\sim 60\%$ e $\sim 75\%$, respectivamente, como a aplicação da filtragem BWTD e do sistema inteligente de classificação.

Portanto, a conclusão geral é que o sistema proposto EMD-IRNI apresentou um melhor desempenho, no que se refere à acurácia, resolução de frequência, resiliência ao ruído e comportamento dinâmico, em comparação a todos os métodos investigados nos três estudos de caso, superando também a análise DEMON padrão.

5 Conclusões e Perspectivas

Os sistemas de SONAR passivo são de grande importância em diversas aplicações civis e militares. Neste último caso, são empregados na detecção, classificação e monitoramento de embarcações em operações navais com submarinos. A DEMON é a ferramenta tradicionalmente utilizada na análise espectral de sinais de SONAR passivo. No entanto, a STFT, método em que se baseia, apresenta limitações quanto às resoluções tempo-frequência (TF), o que prejudica o desempenho na estimação dos parâmetros estáticos e dinâmicos das embarcações e, conseqüentemente, na detecção, classificação e monitoramento. Além disso, os sinais de SONAR passivo são geralmente não-lineares, não-estacionários e muito ruidosos, com banda de frequência compartilhada entre o sinal de interesse e o próprio ruído. Essas características tornam inadequada a utilização de métodos lineares convencionais de redução de ruído.

Esta pesquisa de doutorado apresentou um sistema inteligente de análise TF com redução de ruído para sinais de SONAR passivo, o EMD-IRNI, com o objetivo de disponibilizar uma ferramenta alternativa à análise DEMON padrão. O sistema proposto é baseado no método de análise espectral denominada transformada Hilbert-Huang (HHT), em que é utilizada a decomposição empírica em modos (EMD).

Com a utilização da variante HHT-VMD, obteve-se representações TF (HS) e em frequência (MHS) contendo componentes espectrais mais precisos e com maior resolução TF, comparadas àquelas obtidas com a DEMON padrão, o que permite a melhoria do desempenho na detecção, classificação e monitoramento de eventos dinâmicos de embarcações.

A adoção de uma estratégia de redução de ruído baseada em um classificador SVM para seleção das IMF-T e eliminação das IMF-R, associada à filtragem BWTD das IMF-T selecionadas, possibilitou o aumento significativo da SNR do sistema. Como consequência, a VMD apresentou um melhor desempenho em termos de resolução em frequência e separação dos componentes espectrais nas IMFs do sinal processado.

A escolha do classificador SVM, junto com a utilização da validação cruzada (VC), permitiram reduzir as limitações impostas pela disponibilidade de um pequeno conjunto de sinais experimentais de SONAR passivo. No caso da VC, o objetivo também foi avaliar a significância estatística dos resultados.

Por razões estratégicas, além da limitação da quantidade de sinais experimentais disponíveis, restritos a poucos cenários de aquisição, no decorrer da pesquisa também houve falta de informações mais detalhadas sobre características de cenários reais de operação do sistema SONAR em aplicações militares, a serem seguidas no projeto, implementação e avaliação do sistema proposto.

Na avaliação do sistema proposto em operação, evidenciou-se alguns limites de seu desempenho, impostos fundamentalmente pelo ruído incidente, que provavelmente influenciou na ocorrência de 10 erros de classificação. No entanto, a partir dessa constatação, surgiram

perspectivas de futuros trabalhos sobre possíveis estratégias de otimização do método de redução de ruído adotado na presente pesquisa, baseado na BWTD. Nesse sentido, será necessária uma investigação mais aprofundada sobre características específicas do ruído ambiental incidente em sinais de SONAR passivo, que permitam estabelecer critérios de ajuste automáticos do limiar de classificação das IMFs, com base nas informações extraídas do próprio sinal analisado.

As perspectivas de futuros trabalhos também apontam para a investigação de outros algoritmos de aprendizado de máquina, aplicados à classificação das IMF-R e à estimação do ruído de fundo na análise LOFAR (***L**Ow **F**requency and **R**ecording*). Por fim, como próxima etapa da presente pesquisa, a validação do sistema EMD-IRNI juntamente com a equipe de operação do sistema SONAR da Marinha do Brasil.

Portanto, podemos considerar que, de uma forma geral, foi atingido o principal objetivo desta pesquisa, qual seja, apresentar uma forma alternativa de representação da informação acústica de interesse contida no sinal de SONAR passivo, com base no método de análise TF de sinais HHT-EMD. Essa proposta inicial se concretizou na implementação do sistema inteligente EMD-IRNI, em que o método de análise espectral baseado na STFT, tradicionalmente utilizado na análise DEMON, foi substituído por outro de melhor desempenho, a HHT-EMD.

Referências

- 1 MOURA, N. N. de. Detecção e classificação de sinais de sonar passivo usando métodos de separação cega de fontes. *COPPE/UFRJ*, 2013.
- 2 KIPNIS, D.; LEVY, Y.; DIAMANT, R. Sonar point cloud processing to identify sea turtles by pattern analysis. *IEEE Journal of Oceanic Engineering*, IEEE, 2022. Disponível em: <<https://doi.org/10.1109/JOE.2022.3214274>>.
- 3 SHEN, W.; PENG, Z.; ZHANG, J. Identification and counting of fish targets using adaptive resolution imaging sonar. *Journal of Fish Biology*, Wiley Online Library, 2023. Disponível em: <<https://doi.org/10.1111/jfb.15349>>.
- 4 SUNG, M.; SONG, Y.-W.; YU, S.-C. Seabed object's height estimation method utilizing tilt angle changes of imaging sonar. In: *2023 IEEE Underwater Technology (UT)*. [s.n.], 2023. p. 1–5. Disponível em: <<https://doi.org/10.1109/UT49729.2023.10103406>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 5 BRADBURY, G. et al. Testing a novel sonar-based approach for measuring water depth and monitoring sediment storage in beaver ponds. *River Research and Applications*, Wiley Online Library, v. 39, n. 2, p. 266–273, 2023. Disponível em: <<https://doi.org/10.1002/rra.4082>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 6 ZHAO, Y. et al. Seabed sediments classification based on side-scan sonar images using dimension-invariant residual network. *Applied Ocean Research*, Elsevier, v. 130, p. 103429, 2023. Disponível em: <<https://doi.org/10.1016/j.apor.2022.103429>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 7 CHOU, Y.-C. et al. Mechanical imaging sonar-based auv wall following in a water tank. In: IEEE. *2023 IEEE Underwater Technology (UT)*. 2023. p. 1–5. Disponível em: <<https://doi.org/10.1109/UT49729.2023.10103400>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 8 TANG, Y. et al. Auv-based side-scan sonar real-time method for underwater-target detection. *Journal of Marine Science and Engineering*, MDPI, v. 11, n. 4, p. 690, 2023. Disponível em: <<https://doi.org/10.3390/jmse11040690>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 9 SIBLEY, E. C. et al. Sound sees more: A comparison of imaging sonars and optical cameras for estimating fish densities at artificial reefs. *Fisheries Research*, Elsevier, v. 264, p. 106720, 2023. Disponível em: <<https://doi.org/10.1016/j.fishres.2023.106720>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 10 HELMINEN, J.; LINNANSAARI, T. Combining imaging sonar counting and underwater camera species apportioning to estimate the number of atlantic salmon (*salmo salar*) and striped bass (*morone saxatilis*) in the miramichi river, new brunswick, canada. *North American Journal of Fisheries Management*, Wiley Online Library, 2023. Disponível em: <<https://doi.org/10.1002/nafm.10889>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 11 JR., N. N. de M. Detecção de novidade para sistemas de sonar passivo. *COPPE/UFRJ*, 2018.
- 12 HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 454, n. 1971, p. 903–995, 1998. Disponível em: <<https://doi.org/10.1098/rspa.1998.0193>>.
- 13 HUANG, N. E. Introduction to the hilbert–huang transform and its related mathematical problems. In: *Hilbert–Huang transform and its applications*. World Scientific, 2014. p. 1–26. Disponível em: <https://doi.org/10.1142/9789812703347_0001>.
- 14 HUANG, N. E. et al. On hilbert spectral representation: a true time-frequency representation for nonlinear and nonstationary data. *Advances in adaptive data analysis*, World Scientific, v. 3, n. 01n02, p. 63–93, 2011. Disponível em: <<https://doi.org/10.1142/S1793536911000659>>.
- 15 HUANG, N. E. *Hilbert-Huang transform and its applications*. [S.l.]: World Scientific, 2014. v. 16. Citado na página 1.6 Citado 1 vezes nas páginas 1.

- 16 SARNO, E. P. et al. Empirical mode decomposition: Theory and applications in underwater acoustics - journal of communication and information systems. v. 37, p. 145–167, 01 2022. Disponível em: <<https://doi.org/10.14209/jcis.2022.16>>.
- 17 DINIZ, P. S.; SILVA, E. A. da; NETTO, S. L. *Processamento Digital de Sinais: Projeto e Análise de Sistemas*. [S.l.]: Bookman Editora, 2014. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 18 OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-time signal processing*. Pearson Education India, 2014. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/294797>>.
- 19 MALLAT, S. *A wavelet tour of signal processing*. [S.l.]: Elsevier, 1999.
- 20 YAN, R.; GAO, R. X. Hilbert–huang transform-based vibration signal analysis for machine health monitoring. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 55, n. 6, p. 2320–2329, 2006. Disponível em: <<https://doi.org/10.1109/TIM.2006.887042>>.
- 21 GAO, R. X.; YAN, R. Non-stationary signal processing for bearing health monitoring. *International journal of manufacturing research*, Inderscience Publishers, v. 1, n. 1, p. 18–40, 2006. Disponível em: <<https://doi.org/10.1504/IJMR.2006.010701>>. Citado na página 1.6 Citado 1 vezes nas páginas 1.
- 22 LIU, J. F. et al. Remote fault diagnosis system based on emd and svm for heavy rolling-mills. In: TRANS TECH PUBL. *Advanced Materials Research*. 2014. v. 889, p. 681–686. Disponível em: <<http://dx.doi.org/10.4028/www.scientific.net/AMR.889-890.681>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 23 FURLONG, T.; REICHARD, K. Machining tool and bearing failure analysis using the orthogonal hilbert-huang transform on vibration and motor current datasets. In: *Annual Conference of the PHM Society*. [s.n.], 2022. v. 14, n. 1. Disponível em: <<https://doi.org/10.36001/phmconf.2022.v14i1.3224>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 24 QI, B. et al. Application of emd combined with deep learning and knowledge graph in bearing fault. *Journal of Signal Processing Systems*, Springer, p. 1–20, 2023. Disponível em: <<https://doi.org/10.1007/s11265-023-01845-z>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 25 REN, Y.; SUGANTHAN, P. N.; SRIKANTH, N. A novel empirical mode decomposition with support vector regression for wind speed forecasting. *IEEE transactions on neural networks and learning systems*, IEEE, v. 27, n. 8, p. 1793–1798, 2014. Disponível em: <<https://doi.org/10.1109/TNNLS.2014.2351391>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 26 YANG, S.; YUAN, A.; YU, Z. A novel model based on ceemdan, iwoa, and lstm for ultra-short-term wind power forecasting. *Environmental Science and Pollution Research*, Springer, v. 30, n. 5, p. 11689–11705, 2023. Disponível em: <<https://doi.org/10.1007/s11356-022-22959-0>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 27 BOMMIDI, B. S.; TEEPARTHI, K.; KOSANA, V. Hybrid wind speed forecasting using iceemdan and transformer model with novel loss function. *Energy*, Elsevier, v. 265, p. 126383, 2023. Disponível em: <<https://doi.org/10.1016/j.energy.2022.126383>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 28 ALVANITOPOULOS, P.-F. et al. Solar radiation time-series prediction based on empirical mode decomposition and artificial neural networks. In: SPRINGER. *IFIP International Conference on Artificial Intelligence Applications and Innovations*. 2014. p. 447–455. Disponível em: <https://doi.org/10.1007/978-3-662-44654-6_44>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 29 GHIMIRE, S. et al. Improved complete ensemble empirical mode decomposition with adaptive noise deep residual model for short-term multi-step solar radiation prediction. *Renewable Energy*, Elsevier, v. 190, p. 408–424, 2022. Disponível em: <<https://doi.org/10.1016/j.renene.2022.03.120>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 30 GUERMOUI, M. et al. Potential assessment of the tvf-emd algorithm in forecasting hourly global solar radiation: Review and case studies. *Journal of Cleaner Production*, Elsevier, v. 385, p. 135680, 2023. Disponível em: <<https://doi.org/10.1016/j.jclepro.2022.135680>>.
- 31 GURYANOV, F.; KRYLOV, A. Fast medical image registration using bidirectional empirical mode decomposition. *Signal Processing: Image Communication*, Elsevier, v. 59, p. 12–17, 2017. Disponível em: <<https://doi.org/10.1016/j.image.2017.04.003>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.

- 32 KISA, D. H. et al. Classification of hand gestures using semg signals and hilbert-huang transform. In: IEEE. *2022 30th European Signal Processing Conference (EUSIPCO)*. 2022. p. 1293–1297. Disponível em: <<https://doi.org/10.23919/EUSIPCO55093.2022.9909748>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 33 ERFIANTO, B.; RIZAL, A.; HADIYOSO, S. Empirical mode decomposition and hilbert spectrum for abnormality detection in normal and abnormal walking transitions. *International Journal of Environmental Research and Public Health*, MDPI, v. 20, n. 5, p. 3879, 2023. Disponível em: <<https://doi.org/10.3390/ijerph20053879>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 34 ZAO, L.; COELHO, R. Empirical signal decomposition for acoustic noise detection. In: IEEE. *2016 IEEE Sensor Array and Multichannel Signal Processing Workshop (SAM)*. 2016. p. 1–5. Disponível em: <<https://doi.org/10.1109/SAM.2016.7569740>>.
- 35 CALDEIRA, A.; COELHO, R. Eemd-if based method for underwater noisy acoustic signals enhancement in time-domain. *IEEE Signal Processing Letters*, v. 30, p. 294–298, 2023. Disponível em: <<https://doi.org/10.1109/LSP.2023.3258219>>.
- 36 COELHO, R. et al. Empirical mode decomposition theory applied to speech enhancement. In: *Signals and Images: Advances and Results in Speech, Estimation, Compression, Recognition, Filtering and Processing*. [S.l.]: CRC Press, 2015. p. 123–153. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 37 MEDINA, C.; COELHO, R.; ZAO, L. Impulsive noise detection for speech enhancement in hht domain. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, v. 29, p. 2244–2253, 2021. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 38 FARIAS, F.; COELHO, R. Blind adaptive mask to improve intelligibility of non-stationary noisy speech. *IEEE Signal Processing Letters*, v. 28, p. 1170–1174, 2021. Disponível em: <<https://doi.org/10.1109/LSP.2021.3086405>>. Citado na página 2.6 Citado 1 vezes nas páginas 2.
- 39 QUEIROZ, A.; COELHO, R. Noisy speech based temporal decomposition to improve fundamental frequency estimation. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, v. 30, p. 2504–2513, 2022. Disponível em: <<https://doi.org/10.1109/TASLP.2022.3190670>>.
- 40 FLECK, L. et al. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016. Disponível em: <<https://doi.org/10.3895/recit.v7i15.4330>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 41 HAYKIN, S. *Neural networks and learning machines, 3/E*. Pearson Education India, 2009. Disponível em: <<https://doi.org/>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 42 KUNCHEVA, L. I. *Combining pattern classifiers: methods and algorithms*. John Wiley & Sons, 2014. Disponível em: <<https://doi.org/10.1002/9781118914564>>.
- 43 SRIVASTAVA, G.; BAG, S. Modern-day marketing concepts based on face recognition and neuro-marketing: a review and future research directions. *Benchmarking: An International Journal*, Emerald Publishing Limited, 2023. Disponível em: <<https://doi.org/10.1108/BIJ-09-2022-0588>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 44 DUBEY, R. K.; CHOUBEY, D. K. Deconstructive human face recognition using deep neural network. *Multimedia Tools and Applications*, Springer, p. 1–16, 2023. Disponível em: <<https://doi.org/10.1007/s11042-023-15107-4>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 45 PAGUIRIGAN, R. F. F. et al. Machine learning approaches to facial recognition: A survey. In: *2023 International Conference on Electronics, Information, and Communication (ICEIC)*. [s.n.], 2023. p. 1–6. Disponível em: <<https://doi.org/10.1109/ICEIC57457.2023.10049964>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 46 SALAROLLI, P. F. et al. Algoritmos de navegação de robôs móveis com tração nas quatro rodas utilizando sistemas de localização absolutos gnss e rtk. *Peer Review*, v. 5, 2023. Disponível em: <<https://doi.org/10.53660/255.prw414b>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 47 LIU, W. et al. A systematic survey of control techniques and applications: From autonomous vehicles to connected and automated vehicles. *arXiv preprint arXiv:2303.05665*, 2023. Disponível em: <<https://doi.org/10.48550/arXiv.2303.05665>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.

- 48 HE, K. et al. Accelerated and refined lane-level route-planning method based on a new road network model for autonomous vehicle navigation. *World Electric Vehicle Journal*, MDPI, v. 14, n. 4, p. 98, 2023. Disponível em: <<https://doi.org/10.3390/wevj14040098>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 49 PRAVEEN, R.; PABITHA, P. A secure lightweight fuzzy embedder based user authentication scheme for internet of medical things applications. *Journal of Intelligent & Fuzzy Systems*, IOS Press, n. Preprint, p. 1–20, 2023. Disponível em: <<https://doi.org/10.3233/JIFS-223617>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 50 SINGH, S. P.; TIWARI, S. A dual multimodal biometric authentication system based on woa-ann and ssa-dbn techniques. *Sci*, MDPI, v. 5, n. 1, p. 10, 2023. Disponível em: <<https://doi.org/10.3390/sci5010010>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 51 SHEIK, S. A.; MUNIYANDI, A. P. Secure authentication schemes in cloud computing with glimpse of artificial neural networks: A review. *Cyber Security and Applications*, Elsevier, v. 1, p. 100002, 2023. Disponível em: <<https://doi.org/10.1016/j.csa.2022.100002>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 52 DAS, N.; SWARNA, R. N.; HOSSAIN, M. S. Deep learning-based circular disk type radar target detection in complex environment. *Physical Communication*, Elsevier, v. 58, p. 102014, 2023. Disponível em: <<https://doi.org/10.1016/j.phycom.2023.102014>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 53 SAFFARI, A.; ZAHIRI, S.-h.; KHISHE, M. Automatic recognition of sonar targets using feature selection in micro-doppler signature. *Defence Technology*, Elsevier, v. 20, p. 58–71, 2023. Disponível em: <<https://doi.org/10.1016/j.dt.2022.05.007>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 54 SINGH, R.; CHITRANSHI, J. Identification of human capital management policy for the officers serving in the unit in the indian army. In: AIP PUBLISHING LLC. *AIP Conference Proceedings*. 2023. v. 2523, n. 1, p. 030001. Disponível em: <<https://doi.org/10.1063/5.0110639>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 55 LUO, X. et al. A survey of underwater acoustic target recognition methods based on machine learning. *Journal of Marine Science and Engineering*, MDPI, v. 11, n. 2, p. 384, 2023. Disponível em: <<https://doi.org/10.3390/jmse11020384>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 56 SONG, Y.; LIU, F.; SHEN, T. Plda in i-vector based underwater acoustic signals classification. *Ships and Offshore Structures*, Taylor & Francis, p. 1–9, 2023. Disponível em: <<https://doi.org/10.1080/17445302.2023.2169066>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 57 SALIM, O. N. M.; ADNAN, S. A.; MUTLAG, A. H. Artificial neural network-based transmission power control for underwater wireless optical communication system. *Engineering and Technology Journal*, University of Technology-Iraq, v. 41, n. 2, p. 1–11, 2023. Disponível em: <<https://doi.org/10.30684/etj.2022.136247.1309>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 58 KURANI, A. et al. A comprehensive comparative study of artificial neural network (ann) and support vector machines (svm) on stock forecasting. *Annals of Data Science*, Springer, v. 10, n. 1, p. 183–208, 2023. Disponível em: <<https://doi.org/10.1007/s40745-021-00344-x>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 59 BEHERA, J. et al. Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 120, p. 105843, 2023. Disponível em: <<https://doi.org/10.1016/j.engappai.2023.105843>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 60 ZHANG, Y.; SONG, Y.; WEI, G. A feature-enhanced long short-term memory network combined with residual-driven ν support vector regression for financial market prediction. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 118, p. 105663, 2023. Disponível em: <<https://doi.org/10.1016/j.engappai.2022.105663>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 61 FISHER, R. A. The use of multiple measurements in taxonomic problems. *Annals of eugenics*, Wiley Online Library, v. 7, n. 2, p. 179–188, 1936. Disponível em: <<https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>>.

- 62 GHOJOGH, B. et al. Fisher discriminant analysis. In: *Elements of Dimensionality Reduction and Manifold Learning*. Springer, 2023. p. 155–184. Disponível em: <https://doi.org/10.1007/978-3-031-10602-6_6>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 63 LORENA, A. C.; CARVALHO, A. C. D. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. Disponível em: <<https://doi.org/10.22456/2175-2745.5690>>.
- 64 BRIDGELALL, R. Tutorial on support vector machines. 2022. Disponível em: <<https://doi.org/10.21203/rs.3.rs-1200362/v2>>. Citado na página 3.6 Citado 1 vezes nas páginas 3.
- 65 FRANCISCO, F.; SUNDBERG, J. Detection of visual signatures of marine mammals and fish within marine renewable energy farms using multibeam imaging sonar. *Journal of Marine Science and Engineering*, MDPI, v. 7, n. 2, p. 22, 2019. Disponível em: <<https://doi.org/10.3390/jmse7020022>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 66 WEI, Y.; DUAN, Y.; AN, D. Monitoring fish using imaging sonar: Capacity, challenges and future perspective. *Fish and Fisheries*, Wiley Online Library, v. 23, n. 6, p. 1347–1370, 2022. Disponível em: <<https://doi.org/10.1111/faf.12693>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 67 LONG, H. et al. Underwater forward-looking sonar images target detection via speckle reduction and scene prior. *IEEE Transactions on Geoscience and Remote Sensing*, v. 61, p. 1–13, 2023. Disponível em: <<https://doi.org/10.1109/TGRS.2023.3248605>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 68 RIBEIRO, F. J. L.; PEDROZA, A. d. C. P.; COSTA, L. H. M. K. Deepwater monitoring system in underwater delay/disruption tolerant network. *IEEE Latin America Transactions*, IEEE, v. 10, n. 1, p. 1324–1331, 2012. Disponível em: <<https://doi.org/10.1109/TLA.2012.6142480>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 69 ZHANG, Y. et al. Submarine pipeline tracking technology based on auvs with forward looking sonar. *Applied Ocean Research*, Elsevier, v. 122, p. 103128, 2022. Disponível em: <<https://doi.org/10.1016/j.apor.2022.103128>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 70 PAN, H. et al. Underwater acoustic technology-based monitoring of oil spill: A review. *Journal of Marine Science and Engineering*, MDPI, v. 11, n. 4, p. 870, 2023. Disponível em: <<https://doi.org/10.3390/jmse11040870>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 71 CHEN, B. et al. Damage detection of underwater foundation of a chinese ancient stone arch bridge via sonar-based techniques. *Measurement*, Elsevier, v. 169, p. 108283, 2021. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.108283>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 72 LI, X. et al. A method of underwater bridge structure damage detection method based on a lightweight deep convolutional network. *IET Image Processing*, Wiley Online Library, v. 16, n. 14, p. 3893–3909, 2022. Disponível em: <<https://doi.org/10.1049/ipr2.12602>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 73 SHEN, S.; CAO, Z.; LAI, C. Scanning scheme for underwater high-rise pile cap foundation based on imaging sonar. *Sustainability*, MDPI, v. 15, n. 8, p. 6402, 2023. Disponível em: <<https://doi.org/10.3390/su15086402>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 74 SHEN, S. et al. Rapid three-dimensional reconstruction of underwater defective pile based on two-dimensional images obtained using mechanically scanned imaging sonar. *Structural Control and Health Monitoring*, Hindawi, v. 2023, 2023. Disponível em: <<https://doi.org/10.1155/2023/3647434>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 75 GUSSEN, C. M. et al. A survey of underwater wireless communication technologies. *Journal of Communication and Information Systems*, v. 31, n. 1, p. 242–255, 2016. Disponível em: <<https://doi.org/10.14209/jcis.2016.22>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 76 JOUHARI, M. et al. Underwater wireless sensor networks: A survey on enabling technologies, localization protocols, and internet of underwater things. *IEEE Access*, IEEE, v. 7, p. 96879–96899, 2019. Disponível em: <<https://doi.org/10.1109/ACCESS.2019.2928876>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.

- 77 ZHANG, Y. et al. Multi-target tracking in multi-static networks with autonomous underwater vehicles using a robust multi-sensor labeled multi-bernoulli filter. *Journal of Marine Science and Engineering*, MDPI, v. 11, n. 4, p. 875, 2023. Disponível em: <<https://doi.org/10.3390/jmse11040875>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 78 HODGES, R. P. *Underwater acoustics: Analysis, design and performance of sonar*. [S.l.]: John Wiley & Sons, 2011.
- 79 WOLFF, L. M.; BADRI-HOEHER, S. Imaging sonar-based fish detection in shallow waters. In: IEEE. *2014 Oceans-St. John's*. 2014. p. 1–6. Disponível em: <<https://doi.org/https://doi.org/10.1109/OCEANS.2014.7003213>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 80 MANZANO-ROTH, R. et al. Dive characteristics of cross seamount beaked whales from long-term passive acoustic monitoring at the pacific missile range facility, kauai. *Marine Mammal Science*, Wiley Online Library, v. 39, n. 1, p. 22–41, 2023. Disponível em: <<https://doi.org/10.1111/mms.12959>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 81 LEE, Y. et al. Underwater robot exploration and identification using dual imaging sonar: Basin test. In: IEEE. *2017 IEEE Underwater Technology (UT)*. 2017. p. 1–4. Disponível em: <<https://doi.org/10.1109/UT.2017.7890335>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 82 MUDULI, R. K. et al. A review on recent advancements in signal processing and sensing technologies for auvs. In: *2022 IEEE 2nd International Symposium on Sustainable Energy, Signal Processing and Cyber Security (iSSSC)*. [s.n.], 2022. p. 1–6. Disponível em: <<https://doi.org/10.1109/iSSSC56467.2022.10051366>>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 83 STIFANI, M. et al. Sensors, measurements, and analysis for underwater acoustic investigation. In: *Measurement for the Sea: Supporting the Marine Environment and the Blue Economy*. Springer, 2022. p. 129–156. Disponível em: <https://doi.org/10.1007/978-3-030-82024-4_6>. Citado na página 5.6 Citado 1 vezes nas páginas 5.
- 84 ETTER, P. C. *Underwater acoustic modeling and simulation*. [S.l.]: CRC press, 2018.
- 85 LI, Z.-x.; LI, Y.-a.; ZHANG, K. An adaptive feature extraction technique for ship-radiated noise based on weighted multiscale mathematical morphological filtering. *Journal of Vibration and Control*, SAGE Publications Sage UK: London, England, p. 10775463221148255, 2023. Disponível em: <<https://doi.org/10.1177/10775463221148255>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 86 KHATAMI, R.; CHEN, B.; CHEN, Y. C. Optimal voyage scheduling of all-electric ships considering underwater radiated noise. *Transportation Research Part C: Emerging Technologies*, Elsevier, v. 148, p. 104024, 2023. Disponível em: <<https://doi.org/10.1016/j.trc.2023.104024>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 87 YANG, Q. et al. Statistics of underwater ambient noise at high sea states arisen from typhoon out zones in the philippine sea and south china sea. *Acta Oceanologica Sinica*, Springer, v. 41, n. 7, p. 153–165, 2022. Disponível em: <<https://doi.org/https://doi.org/10.1007/s13131-022-1991-7>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 88 HU, N. et al. Spectral level prediction model of ocean ambient noise based on ga-lm-bp neural network. *Acoustics Australia*, Springer, p. 1–14, 2023. Disponível em: <<https://doi.org/10.1007/s40857-023-00295-8>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 89 KAWADE, A. N. et al. Analysis of ship noise from underwater ambient noise. In: IEEE. *2016 Conference on Advances in Signal Processing (CASP)*. 2016. p. 265–269. Disponível em: <<https://doi.org/10.1109/CASP.2016.7746177>>.
- 90 DANIEL, J. M. et al. An advanced prediction model for underwater noise emissions of ships. *Journal of Ship Production and Design*, SNAME, v. 38, n. 04, p. 220–238, 2022. Disponível em: <<https://doi.org/10.5957/JSPD.06210017>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 91 JAVIER, R. F. et al. Analysis of the underwater radiated noise generated by hull vibrations of the ships. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 23, n. 2, p. 1035, 2023. Disponível em: <<https://doi.org/10.3390/s23021035>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.

- 92 RODRIGO, F. J. et al. Analysis of the underwater radiated noise generated by hull vibrations of the ships. MDPI, 2023. Disponível em: <<https://doi.org/10.3390/s23021035>>. Citado na página 6.6 Citado 1 vezes nas páginas 6.
- 93 WITTEKIND, D.; SCHUSTER, M. Propeller cavitation noise and background noise in the sea. *Ocean Engineering*, Elsevier, v. 120, p. 116–121, 2016. Disponível em: <<https://doi.org/10.1016/j.oceaneng.2015.12.060>>.
- 94 ZHOU, K. et al. Research on propeller cavitation wake characteristics based on multivariate statistical modeling method. *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, SAGE Publications Sage UK: London, England, p. 14750902231164789, 2023. Disponível em: <<https://doi.org/10.1177/14750902231164789>>.
- 95 MOLLA, M. K. I.; HIROSE, K.; MINEMATSU, N. Audio source separation from the mixture using empirical mode decomposition with independent subspace analysis. In: *Eighth International Conference on Spoken Language Processing*. [s.n.], 2004. Disponível em: <<https://doi.org/cir.nii.ac.jp/crid/1571698600139926912>>. Citado na página 7.6 Citado 1 vezes nas páginas 7.
- 96 WEI, K.; LIU, Z.; ZHANG, X. Research of underwater acoustic confrontation technology based on warship radiated noise modeling. In: IEEE. *2014 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*. 2014. p. 659–662. Disponível em: <<https://doi.org/10.1109/ICSPCC.2014.6986276>>. Citado na página 7.6 Citado 1 vezes nas páginas 7.
- 97 ANTONI, J.; HANSON, D. Detection of surface ships from interception of cyclostationary signature with the cyclic modulation coherence. *IEEE Journal of Oceanic Engineering*, IEEE, v. 37, n. 3, p. 478–493, 2012. Disponível em: <<https://doi.org/10.1109/JOE.2012.2195852>>.
- 98 BYUN, S.-H. et al. Cyclostationary analysis of underwater noise for vehicle propeller monitoring. In: IEEE. *OCEANS 2016 MTS/IEEE Monterey*. 2016. p. 1–4. Disponível em: <<https://doi.org/10.1109/OCEANS.2016.7761303>>. Citado na página 7.6 Citado 1 vezes nas páginas 7.
- 99 BARROS, R. E. de B.; EBECKEN, N. F. Development of a ship classification method based on convolutional neural network and cyclostationarity analysis. *Mechanical Systems and Signal Processing*, Elsevier, v. 170, p. 108778, 2022. Disponível em: <<https://doi.org/10.1016/j.ymssp.2021.108778>>. Citado na página 7.6 Citado 1 vezes nas páginas 7.
- 100 BAHRAMI, N.; KHAMIS, N. H. H.; BAHAROM, A. Evaluation of underwater acoustical intermittent ambient noise. In: IEEE. *2015 IEEE 11th International Colloquium on Signal Processing & Its (CSPA)*. 2015. p. 11–14. Disponível em: <<https://doi.org/10.1109/CSPA.2015.7225609>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 101 HALLIDAY, W. D. et al. Acoustic detections of arctic marine mammals near ulukhaktok, northwest territories, canada. *Canadian Journal of Zoology*, NRC Research Press, v. 97, n. 1, p. 72–80, 2019. Disponível em: <<https://doi.org/10.1139/cjz-2018-0077>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 102 LAPLANTE, J.-F.; AKHLOUFI, M. A.; GERVAISE, C. Deep learning for marine bioacoustics and fish classification using underwater sounds. In: IEEE. *2022 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*. 2022. p. 288–293. Disponível em: <<https://doi.org/10.1109/CCECE49351.2022.9918242>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 103 MANCUSI, M. et al. Fish sounds: towards the evaluation of marine acoustic biodiversity through data-driven audio source separation. *arXiv preprint arXiv:2201.05013*, 2022. Disponível em: <<https://doi.org/10.48550/arXiv.2201.05013>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 104 RECKENDORF, A.; SEIDELIN, L.; WAHLBERG, M. Marine mammal acoustics. In: *Marine Mammals: A Deep Dive into the World of Science*. [S.l.]: Springer International Publishing Cham, 2023. p. 15–31. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 105 BORMANN, P.; WIELANDT, E. Seismic signals and noise. In: *New manual of seismological observatory practice 2 (NMSOP2)*. Deutsches GeoForschungsZentrum GFZ, 2013. p. 1–62. Disponível em: <https://doi.org/10.2312/GFZ.NMSOP-2_ch4>. Citado na página 8.6 Citado 1 vezes nas páginas 8.

- 106 KIMMAN, W.; CAMPMAN, X.; TRAMPERT, J. Characteristics of seismic noise: fundamental and higher mode energy observed in the northeast of the netherlands. *Bulletin of the Seismological Society of America*, Seismological Society of America, v. 102, n. 4, p. 1388–1399, 2012. Disponível em: <<https://doi.org/10.1785/0120110069>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 107 SAADIA, B.; FOTOPOULOS, G. Characterizing ambient seismic noise in an urban park environment. *Sensors*, MDPI, v. 23, n. 5, p. 2446, 2023. Disponível em: <<https://doi.org/10.3390/s23052446>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 108 MAJIDIAN, H.; WANG, L.; ENSHAEI, H. Part. a: A review of the real-time sea-state estimation, using wave buoy analogy. *Ocean Engineering*, Elsevier, p. 111684, 2022. Disponível em: <<https://doi.org/10.1016/j.oceaneng.2022.111684>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 109 BRODTKORB, A. H.; NIELSEN, U. D. Automatic sea state estimation with online trust measure based on ship response measurements. *Control Engineering Practice*, Elsevier, v. 130, p. 105375, 2023. Disponível em: <<https://doi.org/10.1016/j.conengprac.2022.105375>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 110 CHUNG, K. W. et al. Demon acoustic ship signature measurements in an urban harbor. *Advances in Acoustics and Vibration*, Hindawi, v. 2011, 2011. Disponível em: <<https://doi.org/10.1155/2011/952798>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 111 POLLARA, A.; SUTIN, A.; SALLOUM, H. Improvement of the detection of envelope modulation on noise (demon) and its application to small boats. In: IEEE. *OCEANS 2016 MTS/IEEE Monterey*. 2016. p. 1–10. Disponível em: <<https://doi.org/https://doi.org/10.1109/OCEANS.2016.7761197>>.
- 112 HAN, H. S. et al. Development of an evaluation method to determine cavitation inception speed with aft hull vibration using kurtosis of the demon spectrum. *Ocean Engineering*, Elsevier, v. 152, p. 167–180, 2018. Disponível em: <<https://doi.org/10.1016/j.oceaneng.2018.01.075>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 113 KEMPER, G. et al. An algorithm to obtain boat engine rpm from passive sonar signals based on demon processing and wavelets packets transform. *Journal of Electrical Engineering & Technology*, Springer, v. 14, n. 6, p. 2505–2521, 2019. Disponível em: <<https://doi.org/10.1007/s42835-019-00260-4>>.
- 114 AMBAT, S. K. et al. Performance evaluation of the demon processor for sonar. In: IEEE. *2022 IEEE Region 10 Symposium (TENSYP)*. 2022. p. 1–6. Disponível em: <<https://doi.org/10.1109/TENSYP54529.2022.9864381>>.
- 115 HASHMI, M. A. R.; RAZA, R. H. Novel demon spectra analysis techniques and empirical knowledge based reference criterion for acoustic signal classification. *Journal of Electrical Engineering & Technology*, Springer, v. 18, n. 1, p. 561–578, 2023. Disponível em: <<https://doi.org/10.1007/s42835-022-01167-3>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 116 LIDTKE, A. K. et al. Predicting cavitating propeller noise in off-design conditions using scale-resolving cfd simulations. *Ocean Engineering*, Elsevier, v. 254, p. 111176, 2022. Disponível em: <<https://doi.org/10.1016/j.oceaneng.2022.111176>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 117 LU, J. et al. Fundamental frequency detection of underwater acoustic target using demon spectrum and cnn network. In: IEEE. *2020 3rd International Conference on Unmanned Systems (ICUS)*. 2020. p. 778–784. Disponível em: <<https://doi.org/10.1109/ICUS50048.2020.9274949>>. Citado na página 8.6 Citado 1 vezes nas páginas 8.
- 118 LOURENS, J. Classification of ships using underwater radiated noise. In: IEEE. *COMSIG 88@ m_Southern African Conference on Communications and Signal Processing. Proceedings*. 1988. p. 130–134. Disponível em: <<https://doi.org/10.1109/COMSIG.1988.49315>>. Citado na página 9.6 Citado 1 vezes nas páginas 9.
- 119 WANG, Y.; LI, H.; DAI, W. Application of duffing oscillator in ship propeller blade number recognition. In: IEEE. *2016 IEEE/OES China Ocean Acoustics (COA)*. 2016. p. 1–5. Disponível em: <<https://doi.org/10.1109/COA.2016.7535822>>. Citado na página 9.6 Citado 1 vezes nas páginas 9.

- 120 ZHU, X.; WANG, C.-X.; MA, R. A 2d non-stationary channel model for underwater acoustic communication systems. In: *2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring)*. [s.n.], 2021. p. 1–6. Disponível em: <<https://doi.org/10.1109/VTC2021-Spring51267.2021.9448976>>. Citado na página 9.6 Citado 1 vezes nas páginas 9.
- 121 MOURA, N. N. de; FILHO, E. S.; SEIXAS, J. M. de. Independent component analysis for passive sonar signal processing. In: *Advances in Sonar Technology*. [S.l.]: IntechOpen, 2009.
- 122 RICHARD, O. N. *Sonar signal processing. (acoustic and signal processing library)*. 1991. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/532284>>. Citado na página 9.6 Citado 1 vezes nas páginas 9.
- 123 HAYES, M. H. *Statistical digital signal processing and modeling*. [S.l.]: John Wiley & Sons, 2009. Citado na página 9.6 Citado 1 vezes nas páginas 9.
- 124 MOURA, N. D.; SEIXAS, J. D.; RAMOS, R. Passive sonar signal detection and classification based on independent component analysis. In: *Sonar Systems*. IntechOpen, 2011. Disponível em: <<https://doi.org/10.5772/18286>>. Citado na página 9.6 Citado 1 vezes nas páginas 9.
- 125 OLIVEIRA, R. L.; LIMA, B. S. de; EBECKEN, N. F. Multiway analysis in data sonar classification. *Mechanical Systems and Signal Processing*, Elsevier, v. 45, n. 2, p. 531–541, 2014. Disponível em: <<https://doi.org/10.1016/j.ymssp.2013.11.008>>.
- 126 ESQUEF, P. A. et al. Removal of long pulses from audio signals using two-pass split-window filtering. In: AUDIO ENGINEERING SOCIETY. *Audio Engineering Society Convention 112*. 2002. Disponível em: <<http://www.aes.org/e-lib/browse.cfm?elib=11348>>. Citado na página 10.6 Citado 1 vezes nas páginas 10.
- 127 GAROFOLO, J. et al. Timit acoustic-phonetic continuous speech corpus. *Linguistic Data Consortium*, 11 2023. Disponível em: <<https://doi.org/10.35111/17gk-bn40>>. Citado na página 10.6 Citado 1 vezes nas páginas 10.
- 128 MOLLA, M. K. I.; HIROSE, K. Hilbert spectrum in time-frequency representation of audio signals considering disjoint orthogonality. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 03, p. 313–336, 2010. Disponível em: <<https://doi.org/10.1142/S1793536910000501>>. Citado na página 11.6 Citado 1 vezes nas páginas 11.
- 129 MORALES, S.; BOWERS, M. E. Time-frequency analysis methods and their application in developmental eeg data. *Developmental Cognitive Neuroscience*, Elsevier, v. 54, p. 101067, 2022. Disponível em: <<https://doi.org/10.1016/j.dcn.2022.101067>>. Citado na página 11.6 Citado 1 vezes nas páginas 11.
- 130 CHEN, X. et al. A statistical instantaneous frequency estimator for high-concentration time-frequency representation. *Signal Processing*, Elsevier, v. 204, p. 108825, 2023. Disponível em: <<https://doi.org/10.1016/j.sigpro.2022.108825>>. Citado na página 11.6 Citado 1 vezes nas páginas 11.
- 131 OPPENHIEM, A. V.; WILLISKY, A. S.; NAWAB, S. H. *Signals and systems*. [S.l.]: Upper Saddle River, USA: Prentice Hall, 1996. Citado na página 11.6 Citado 1 vezes nas páginas 11.
- 132 DINIZ, P. S.; SILVA, E. A. D.; NETTO, S. L. *Digital signal processing: system analysis and design*. Cambridge University Press, 2010. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/560356>>. Citado na página 11.6 Citado 1 vezes nas páginas 11.
- 133 MOLLA, M. K. I.; HIROSE, K. Hilbert spectrum in time-frequency representation of audio signals considering disjoint orthogonality. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 03, p. 313–336, 2010. Disponível em: <<https://doi.org/10.1142/S1793536910000501>>.
- 134 WANG, H.; LIU, C. Spurious components introduced by nonlinearity in direct digital synthesis. In: IET. *IET International Radar Conference 2013*. 2013. p. 1–4. Disponível em: <<https://doi.org/10.1049/cp.2013.0447>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 135 ROSŁONIEC, S. Basic methods for eliminating spurious signals. In: *Fundamentals of the Radiolocation and Radionavigation*. Springer, 2023. p. 175–192. Disponível em: <https://doi.org/10.1007/978-3-031-10631-6_10>. Citado na página 12.6 Citado 1 vezes nas páginas 12.

- 136 PENG, Z. K.; CHU, F. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mechanical systems and signal processing*, Elsevier, v. 18, n. 2, p. 199–221, 2004. Disponível em: <[https://doi.org/10.1016/S0888-3270\(03\)00075-X](https://doi.org/10.1016/S0888-3270(03)00075-X)>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 137 LI, M. et al. Short-time fourier transform using odd symmetric window function. *Journal of Dynamics, Monitoring and Diagnostics*, v. 1, n. 1, p. 37–45, 2022. Disponível em: <<https://doi.org/10.37965/jdmd.v2i2.39>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 138 NI, R. et al. Improved empirical wavelet transform (ewt) and its application in non-stationary vibration signal of transformer. *Scientific Reports*, Nature Publishing Group UK London, v. 12, n. 1, p. 17533, 2022. Disponível em: <<https://doi.org/10.1038/s41598-022-22519-z>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 139 LI, G.; YANG, Z.; YANG, H. Noise reduction method of underwater acoustic signals based on uniform phase empirical mode decomposition, amplitude-aware permutation entropy, and pearson correlation coefficient. *Entropy*, MDPI, v. 20, n. 12, p. 918, 2018. Disponível em: <<https://doi.org/10.3390/e20120918>>.
- 140 PACHORI, R. B.; NISHAD, A. Cross-terms reduction in the wigner–ville distribution using tunable-q wavelet transform. *Signal Processing*, Elsevier, v. 120, p. 288–304, 2016. Disponível em: <<https://doi.org/10.1016/j.sigpro.2015.07.026>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 141 RATO, R.; ORTIGUEIRA, M. D.; BATISTA, A. On the hht, its problems, and some solutions. *Mechanical systems and signal processing*, Elsevier, v. 22, n. 6, p. 1374–1394, 2008. Disponível em: <<https://doi.org/10.1016/j.ymssp.2007.11.028>>.
- 142 LEI, Y. et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical systems and signal processing*, Elsevier, v. 35, n. 1-2, p. 108–126, 2013. Disponível em: <<https://doi.org/10.1016/j.ymssp.2012.09.015>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 143 SHARMA, R. et al. Empirical mode decomposition for adaptive am-fm analysis of speech: A review. *Speech Communication*, Elsevier, v. 88, p. 39–64, 2017. Disponível em: <<https://doi.org/10.1016/j.specom.2016.12.004>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 144 STALLONE, A.; CICONE, A.; MATERASSI, M. New insights and best practices for the successful use of empirical mode decomposition, iterative filtering and derived algorithms. *Scientific reports*, Nature Publishing Group, v. 10, n. 1, p. 1–15, 2020. Disponível em: <<https://doi.org/10.1038/s41598-020-72193-2>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 145 SAHU, P. K.; RAI, R. N. Fault diagnosis of rolling bearing based on an improved denoising technique using complete ensemble empirical mode decomposition and adaptive thresholding method. *Journal of Vibration Engineering & Technologies*, Springer, v. 11, n. 2, p. 513–535, 2023. Disponível em: <<https://doi.org/10.1007/s42417-022-00591-z>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 146 ZHANG, Y.; JI, J.; MA, B. Fault diagnosis of reciprocating compressor using a novel ensemble empirical mode decomposition-convolutional deep belief network. *Measurement*, Elsevier, v. 156, p. 107619, 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107619>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 147 JALLI, R. K. et al. Prediction of wind speed with optimized emd based rvfln. In: IEEE. *2020 IEEE-HYDCON*. 2020. p. 1–5. Disponível em: <<https://doi.org/https://doi.org/10.1109/HYDCON48903.2020.9242739>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 148 YU, M. Short-term wind speed forecasting based on random forest model combining ensemble empirical mode decomposition and improved harmony search algorithm. *International Journal of Green Energy*, Taylor & Francis, v. 17, n. 5, p. 332–348, 2020. Disponível em: <<https://doi.org/10.1080/15435075.2020.1731816>>. Citado na página 12.6 Citado 1 vezes nas páginas 12.
- 149 YADAV, H. K.; PAL, Y.; TRIPATHI, M. M. Short-term pv power forecasting using empirical mode decomposition in integration with back-propagation neural network. *Journal of Information and Optimization Sciences*, Taylor & Francis, v. 41, n. 1, p. 25–37, 2020. Disponível em: <<https://doi.org/10.1080/02522667.2020.1714181>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.

- 150 GUPTA, K. et al. Hyp-net: Automated detection of hypertension using deep convolutional neural network and gabor transform techniques with ballistocardiogram signals. *Biocybernetics and Biomedical Engineering*, Elsevier, v. 42, n. 3, p. 784–796, 2022. Disponível em: <<https://doi.org/10.1016/j.bbe.2022.06.001>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 151 BALIARSINGH, S.; PANDA, P. K.; MOHANTY, M. N. Ecg compression using decomposed transform for e-healthcare. In: IEEE. *2022 OITS International Conference on Information Technology (OCIT)*. 2022. p. 501–506. Disponível em: <<https://doi.org/10.1109/OCIT56763.2022.00099>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 152 SALANKAR, N.; MISHRA, P.; GARG, L. Emotion recognition from eeg signals using empirical mode decomposition and second-order difference plot. *Biomedical Signal Processing and Control*, Elsevier, v. 65, p. 102389, 2021. Disponível em: <<https://doi.org/10.1016/j.bspc.2020.102389>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 153 SAMAL, P.; HASHMI, M. F. Ensemble median empirical mode decomposition for emotion recognition using eeg signal. *IEEE Sensors Letters*, IEEE, 2023. Disponível em: <<https://doi.org/10.1109/LSENS.2023.3265682>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 154 RAYACHOTI, E.; TIRUMALASETTY, S.; PRATHIPATI, S. C. Watermarking system for telemedicine based on fabemd. *Multimedia Tools and Applications*, Springer, p. 1–22, 2022. Disponível em: <<https://doi.org/10.1007/s11042-022-13277-1>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 155 ZÜLFİKAR, A.; MEHMET, A. Empirical mode decomposition and convolutional neural network-based approach for diagnosing psychotic disorders from eeg signals. *Applied Intelligence*, Springer, v. 52, n. 11, p. 12103–12115, 2022. Disponível em: <<https://doi.org/10.1007/s10489-022-03252-6>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 156 FANG, T.; ZHENG, C.; WANG, D. Forecasting the crude oil prices with an emd-isbm-fnn model. *Energy*, Elsevier, v. 263, p. 125407, 2023. Disponível em: <<https://doi.org/10.1016/j.energy.2022.125407>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 157 LU, Q. et al. Predicting natural gas prices based on a novel hybrid model with variational mode decomposition. *Computational Economics*, Springer, p. 1–40, 2023. Disponível em: <<https://doi.org/10.1007/s10614-023-10354-x>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 158 YANG, S. et al. Carbon price forecasting based on modified ensemble empirical mode decomposition and long short-term memory optimized by improved whale optimization algorithm. *Science of the Total Environment*, Elsevier, v. 716, p. 137117, 2020. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2020.137117>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 159 YUN, P. et al. Forecasting carbon dioxide emission price using a novel mode decomposition machine learning hybrid model of ceemdan-lstm. *Energy Science & Engineering*, Wiley Online Library, v. 11, n. 1, p. 79–96, 2023. Disponível em: <<https://doi.org/10.1002/ese3.1304>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 160 JIN, X.-B. et al. Hybrid deep learning predictor for smart agriculture sensing based on empirical mode decomposition and gated recurrent unit group model. *Sensors*, MDPI, v. 20, n. 5, p. 1334, 2020. Disponível em: <<https://doi.org/10.3390/s20051334>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 161 DHIFAOU, Z. et al. Exploring the effect of climate risk on agricultural and food stock prices: Fresh evidence from emd-based variable-lag transfer entropy analysis. *Journal of Environmental Management*, Elsevier, v. 326, p. 116789, 2023. Disponível em: <<https://doi.org/10.1016/j.jenvman.2022.116789>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 162 JIN, X.-B. et al. Deep hybrid model based on emd with classification by frequency characteristics for long-term air quality prediction. *Mathematics*, MDPI, v. 8, n. 2, p. 214, 2020. Disponível em: <<https://doi.org/10.3390/math8020214>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 163 WANG, W.; TANG, Q. Combined model of air quality index forecasting based on the combination of complementary empirical mode decomposition and sequence reconstruction. *Environmental Pollution*, Elsevier, v. 316, p. 120628, 2023. Disponível em: <<https://doi.org/10.1016/j.envpol.2022.120628>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.

- 164 ZÃO, L.; COELHO, R.; FLANDRIN, P. Speech enhancement with emd and hurst-based mode selection. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, IEEE, v. 22, n. 5, p. 899–911, 2014. Disponível em: <<https://doi.org/https://doi.org/10.1109/TASLP.2014.2312541>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 165 TAVARES, R.; COELHO, R. Speech enhancement with nonstationary acoustic noise detection in time domain. *IEEE Signal Processing Letters*, IEEE, v. 23, n. 1, p. 6–10, 2015. Disponível em: <<https://doi.org/10.1109/LSP.2015.2495102>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 166 ZHANG, J. et al. Serial-emd: Fast empirical mode decomposition method for multi-dimensional signals based on serialization. *Information Sciences*, Elsevier, v. 581, p. 215–232, 2021. Disponível em: <<https://doi.org/10.1016/j.ins.2021.09.033>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 167 LI, G.; HOU, Y.; YANG, H. A novel method for frequency feature extraction of ship radiated noise based on variational mode decomposition, double coupled duffing chaotic oscillator and multivariate multiscale dispersion entropy. *Alexandria Engineering Journal*, Elsevier, v. 61, n. 8, p. 6329–6347, 2022. Disponível em: <<https://doi.org/10.1016/j.aej.2021.11.059>>.
- 168 ZHU, C. et al. A time-frequency domain detection method for measurement data of non-stationary signals based on optimized hilbert-huang transform. *IEEE Instrumentation & Measurement Magazine*, IEEE, v. 26, n. 2, p. 29–39, 2023. Disponível em: <<https://doi.org/10.1109/MIM.2023.10083022>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 169 LI, Z. et al. A novel underwater acoustic target identification method based on spectral characteristic extraction via modified adaptive chirp mode decomposition. *Entropy*, MDPI, v. 25, n. 4, p. 669, 2023. Disponível em: <<https://doi.org/10.3390/e25040669>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 170 HAN, Z. et al. The time-frequency analysis of the acoustic signal produced in underwater discharges based on variational mode decomposition and hilbert–huang transform. *Scientific Reports*, Nature Publishing Group UK London, v. 13, n. 1, p. 22, 2023. Disponível em: <<https://doi.org/10.1038/s41598-022-27359-5>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 171 ZARE, M.; NOURI, N. M. A novel hybrid feature extraction approach of marine vessel signal via improved empirical mode decomposition and measuring complexity. *Ocean Engineering*, Elsevier, v. 271, p. 113727, 2023. Disponível em: <<https://doi.org/10.1016/j.oceaneng.2023.113727>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 172 URICK, R. J. Principles of underwater sound. *New York*, 1983. Disponível em: <<https://agris.fao.org/agris-search/search.do?recordID=XF2015043767>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 173 DELPRETE, C. et al. Bearing health monitoring based on the orthogonal empirical mode decomposition. *Shock and Vibration*, Hindawi, v. 2020, 2020. Disponível em: <<https://doi.org/10.1155/2020/8761278>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 174 MOLLA, M. K. I.; HIROSE, K.; MINEMATSU, N. Separation of mixed audio signals by decomposing hilbert spectrum with modified emd. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, The Institute of Electronics, Information and Communication Engineers, v. 89, n. 3, p. 727–734, 2006. Disponível em: <<https://doi.org/10.1093/ietfec/e89-a.3.727>>.
- 175 HONG, Y.; YA-AN, L.; GUO-HUI, L. Noise reduction method of ship radiated noise with ensemble empirical mode decomposition of adaptive noise. *Noise Control Engineering Journal*, Institute of Noise Control Engineering, v. 64, n. 2, p. 230–242, 2016. Disponível em: <<https://doi.org/10.3397/1/376374>>. Citado na página 13.6 Citado 1 vezes nas páginas 13.
- 176 ALEXANDROV, T. et al. A review of some modern approaches to the problem of trend extraction. *Econometric Reviews*, Taylor & Francis, v. 31, n. 6, p. 593–624, 2012. Disponível em: <<https://doi.org/10.1080/07474938.2011.608032>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 177 MOGHTADERI, A.; FLANDRIN, P.; BORGNAT, P. Trend filtering via empirical mode decompositions. *Computational Statistics & Data Analysis*, Elsevier, v. 58, p. 114–126, 2013. Disponível em: <<https://doi.org/10.1016/j.csda.2011.05.015>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.

- 178 HUANG, N. E. et al. A confidence limit for the empirical mode decomposition and hilbert spectral analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 459, n. 2037, p. 2317–2345, 2003. Disponível em: <<https://doi.org/10.1098/rspa.2003.1123>>.
- 179 PENG, Z.; PETER, W. T.; CHU, F. A comparison study of improved hilbert–huang transform and wavelet transform: Application to fault diagnosis for rolling bearing. *Mechanical systems and signal processing*, Elsevier, v. 19, n. 5, p. 974–988, 2005. Disponível em: <<https://doi.org/10.1016/j.ymssp.2004.01.006>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 180 AYENU-PRAH, A.; ATTOH-OKINE, N. A criterion for selecting relevant intrinsic mode functions in empirical mode decomposition. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 01, p. 1–24, 2010. Disponível em: <<https://doi.org/10.1142/S1793536910000367>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 181 SOUZA, D. B. de; CHANUSSOT, J.; FAVRE, A.-C. On selecting relevant intrinsic mode functions in empirical mode decomposition: An energy-based approach. In: IEEE. *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2014. p. 325–329. Disponível em: <<https://doi.org/https://doi.org/10.1109/ICASSP.2014.6853611>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 182 MEHBOOB, Z.; YIN, H. Information quantification of empirical mode decomposition and applications to field potentials. *International Journal of Neural Systems*, World Scientific, v. 21, n. 01, p. 49–63, 2011. Disponível em: <<https://doi.org/10.1142/S012906571100264X>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 183 UDDIN, M. B. et al. A new machine learning approach to select adaptive imfs of emd. In: IEEE. *2016 2nd International Conference on Electrical, Computer & Telecommunication Engineering (ICECTE)*. 2016. p. 1–4. Disponível em: <<https://doi.org/https://doi.org/10.1109/ICECTE.2016.7879617>>. Citado na página 15.6 Citado 1 vezes nas páginas 15.
- 184 RILLING, G. et al. On empirical mode decomposition and its algorithms. In: NSIP-03, GRADO (I). *IEEE-EURASIP workshop on nonlinear signal and image processing*. 2003. v. 3, n. 3, p. 8–11. Disponível em: <<https://inria.hal.science/inria-00570628>>.
- 185 FLANDRIN, P.; GONÇALVES, P.; RILLING, G. Emd equivalent filter banks, from interpretation to applications. In: *Hilbert-Huang transform and its applications*. World Scientific, 2005. p. 57–74. Disponível em: <https://doi.org/10.1142/9789812703347_0003>. Citado na página 16.6 Citado 1 vezes nas páginas 16.
- 186 WANG, G. et al. On intrinsic mode function. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 03, p. 277–293, 2010. Disponível em: <<https://doi.org/10.1142/S1793536910000549>>. Citado na página 16.6 Citado 1 vezes nas páginas 16.
- 187 CHEN, D. et al. Solving the problem of runge phenomenon by pseudoinverse cubic spline. In: IEEE. *2014 IEEE 17th International Conference on Computational Science and Engineering*. 2014. p. 1226–1231. Disponível em: <<https://doi.org/https://doi.org/10.1109/CSE.2014.237>>. Citado na página 16.6 Citado 1 vezes nas páginas 16.
- 188 BELANGER, N. External fake constraints interpolation: the end of runge phenomenon with high degree polynomials relying on equispaced nodes–application to aerial robotics motion planning. *indicator*, v. 2, p. 1, 2017. Disponível em: <<https://ima.org.uk/wp/wp-content/uploads/2017/03/Belanger-paper.pdf>>. Citado na página 16.6 Citado 1 vezes nas páginas 16.
- 189 LI, H.; WANG, C.; ZHAO, D. Filter bank properties of envelope modified emd methods. *IET Signal Processing*, Wiley Online Library, v. 12, n. 7, p. 844–851, 2018. Disponível em: <<https://doi.org/https://doi.org/10.1049/iet-spr.2017.0399>>. Citado na página 16.6 Citado 1 vezes nas páginas 16.
- 190 BOASHASH, B. Estimating and interpreting the instantaneous frequency of a signal. i. fundamentals. *Proceedings of the IEEE*, IEEE, v. 80, n. 4, p. 520–538, 1992. Disponível em: <<https://doi.org/10.1109/5.135376>>.

- 191 GABOR, D. Theory of communication. part 1: The analysis of information. *Journal of the Institution of Electrical Engineers-part III: radio and communication engineering*, IET, v. 93, n. 26, p. 429–441, 1946. Disponível em: <<https://doi.org/10.1049/ji-3-2.1946.0074>>.
- 192 PROTHERO, J. et al. Instantaneous spectral analysis. *Journal of Communication and Information Systems*, v. 34, n. 1, p. 12–26, 2019. Disponível em: <<https://orcid.org/0000-0001-6991-2620>>. Citado na página 18.6 Citado 1 vezes nas páginas 18.
- 193 WU, Z.; HUANG, N. E. Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, World Scientific, v. 1, n. 01, p. 1–41, 2009. Disponível em: <<https://doi.org/10.1142/S1793536909000047>>. Citado na página 20.6 Citado 1 vezes nas páginas 20.
- 194 FOSSO, O. B.; MOLINAS, M. Method for mode mixing separation in empirical mode decomposition. *arXiv preprint arXiv:1709.05547*, 2017. Disponível em: <<https://doi.org/10.48550/arXiv.1709.05547>>. Citado na página 20.6 Citado 1 vezes nas páginas 20.
- 195 WANG, Y.-H.; HU, K.; LO, M.-T. Uniform phase empirical mode decomposition: An optimal hybridization of masking signal and ensemble approaches. *IEEE Access*, IEEE, v. 6, p. 34819–34833, 2018. Disponível em: <<https://doi.org/10.1109/ACCESS.2018.2847634>>.
- 196 COLOMINAS, M. A.; SCHLOTTHAUER, G.; TORRES, M. E. Improved complete ensemble emd: A suitable tool for biomedical signal processing. *Biomedical Signal Processing and Control*, Elsevier, v. 14, p. 19–29, 2014. Disponível em: <<https://doi.org/10.1016/j.bspc.2014.06.009>>.
- 197 LI, Y. et al. A new underwater acoustic signal denoising technique based on ceemdan, mutual information, permutation entropy, and wavelet threshold denoising. *Entropy*, MDPI, v. 20, n. 8, p. 563, 2018. Disponível em: <<https://doi.org/10.3390/e20080563>>.
- 198 DRAGOMIRETSKIY, K.; ZOSSO, D. Variational mode decomposition. *IEEE transactions on signal processing*, IEEE, v. 62, n. 3, p. 531–544, 2013. Disponível em: <<https://doi.org/10.1109/TSP.2013.2288675>>.
- 199 LI, Y. et al. A novel feature extraction method for ship-radiated noise based on variational mode decomposition and multi-scale permutation entropy. *Entropy*, MDPI, v. 19, n. 7, p. 342, 2017. Disponível em: <<https://doi.org/10.3390/e19070342>>.
- 200 YAN, H. et al. Mems hydrophone signal denoising and baseline drift removal algorithm based on parameter-optimized variational mode decomposition and correlation coefficient. *Sensors*, MDPI, v. 19, n. 21, p. 4622, 2019. Disponível em: <<https://doi.org/10.3390/s19214622>>.
- 201 YANG, H.; ZHAO, K.; LI, G. A new ship-radiated noise feature extraction technique based on variational mode decomposition and fluctuation-based dispersion entropy. *Entropy*, MDPI, v. 21, n. 3, p. 235, 2019. Disponível em: <<https://doi.org/10.3390/e21030235>>. Citado na página 21.6 Citado 1 vezes nas páginas 21.
- 202 LI, Y.-X. et al. Feature extraction of ship-radiated noise based on permutation entropy of the intrinsic mode function with the highest energy. *Entropy*, MDPI, v. 18, n. 11, p. 393, 2016. Disponível em: <<https://doi.org/10.3390/e18110393>>. Citado na página 21.6 Citado 1 vezes nas páginas 21.
- 203 LI, Y. et al. Denoising and feature extraction algorithms using npe combined with vmd and their applications in ship-radiated noise. *Symmetry*, MDPI, v. 9, n. 11, p. 256, 2017. Disponível em: <<https://doi.org/10.3390/sym9110256>>. Citado na página 21.6 Citado 1 vezes nas páginas 21.
- 204 WU, Z.; HUANG, N. E. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 460, n. 2046, p. 1597–1611, 2004. Disponível em: <<https://doi.org/10.1098/rspa.2003.1221>>. Citado na página 21.6 Citado 1 vezes nas páginas 21.
- 205 KASLOVSKY, D. N.; MEYER, F. G. Noise corruption of empirical mode decomposition and its effect on instantaneous frequency. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 03, p. 373–396, 2010. Disponível em: <<https://doi.org/10.1142/S1793536910000537>>. Citado na página 21.6 Citado 1 vezes nas páginas 21.

- 206 PROAKIS, J. G. *Digital signal processing: principles algorithms and applications*. Pearson Education India, 2001. Disponível em: <<https://doi.org/10.1109/TASSP.1975.1162707>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 207 BOUDRAA, A.; CEXUS, J.; SAIDI, Z. Emd-based signal noise reduction. *International Journal of Signal Processing*, v. 1, n. 1, p. 33–37, 2004. Disponível em: <<https://doi.org/10.1109/TIM.2007.907967>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 208 WANG, H. et al. Ensemble emd-based signal denoising using modified interval thresholding. *IET Signal Processing*, IET, v. 11, n. 4, p. 452–461, 2016. Disponível em: <<https://doi.org/10.1049/iet-spr.2016.0147>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 209 KOPSINIS, Y.; MCLAUGHLIN, S. Development of emd-based denoising methods inspired by wavelet thresholding. *IEEE Transactions on signal Processing*, IEEE, v. 57, n. 4, p. 1351–1362, 2009. Disponível em: <<https://doi.org/10.1109/TSP.2009.2013885>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 210 KOPSINIS, Y.; MCLAUGHLIN, S. Development of emd-based denoising methods inspired by wavelet thresholding. *IEEE Transactions on Signal Processing*, v. 57, n. 4, p. 1351 – 1362, 2009. Disponível em: <<https://doi.org/10.1109/TSP.2009.2013885>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 211 WANG, R. et al. Emd threshold denoising algorithm based on variance estimation. *Circuits, Systems, and Signal Processing*, Springer, v. 37, n. 12, p. 5369–5388, 2018. Disponível em: <<https://doi.org/10.1007/s00034-018-0819-3>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 212 LI, G.; CHANG, W.; YANG, H. A new hybrid model for underwater acoustic signal prediction. *Complexity*, Hindawi, v. 2020, 2020. Disponível em: <<https://doi.org/10.1155/2020/5167469>>. Citado na página 22.6 Citado 1 vezes nas páginas 22.
- 213 LERCH, A. *An introduction to audio content analysis: Applications in signal processing and music informatics*. A. John Wiley Sons, 2012. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/2392638>>.
- 214 PINTÉR, I. Perceptual wavelet-representation of speech signals and its application to speech enhancement. *Computer Speech & Language*, Elsevier, v. 10, n. 1, p. 1–22, 1996. Disponível em: <<https://doi.org/10.1006/csla.1996.0001>>.
- 215 WANG, K.; SHAMMA, S. A.; BYRNE, W. J. Noise robustness in the auditory representation of speech signals. In: IEEE. *1993 IEEE International Conference on Acoustics, Speech, and Signal Processing*. 1993. v. 2, p. 335–338. Disponível em: <<https://doi.org/10.1109/ICASSP.1993.319306>>.
- 216 ZENG, X.-y.; WANG, S.-g. Bark-wavelet analysis and hilbert–huang transform for underwater target recognition. *Defence Technology*, Elsevier, v. 9, n. 2, p. 115–120, 2013. Disponível em: <<https://doi.org/10.1016/j.dt.2012.09.001>>.
- 217 WANG, S.; ZENG, X. Robust underwater noise targets classification using auditory inspired time–frequency analysis. *Applied Acoustics*, Elsevier, v. 78, p. 68–76, 2014. Disponível em: <<https://doi.org/10.1016/j.apacoust.2013.11.003>>.
- 218 ROSAS-OREA, M. et al. A comparative simulation study of wavelet based denoising algorithms. In: IEEE. *15th International Conference on Electronics, Communications and Computers (CONIELECOMP'05)*. 2005. p. 125–130. Disponível em: <<https://doi.org/10.1109/CONIEL.2005.6>>. Citado na página 24.6 Citado 1 vezes nas páginas 24.
- 219 HAYKIN, S. *Neural networks and learning machines*. [S.l.]: New York: Prentice Hall, 2009.
- 220 THARWAT, A. et al. Linear discriminant analysis: A detailed tutorial. *AI communications*, v. 30, n. 2, p. 169–190, 2017. Disponível em: <<https://doi.org/10.3233/AIC-170729>>.
- 221 GABER, T. et al. Human thermal face recognition based on random linear oracle (rlo) ensembles. In: IEEE. *2015 International Conference on Intelligent Networking and Collaborative Systems*. 2015. p. 91–98. Disponível em: <<https://doi.org/https://doi.org/10.1109/INCoS.2015.67>>.

- 222 THARWAT, A. et al. Face sketch synthesis and recognition based on linear regression transformation and multi-classifier technique. In: SPRINGER. *The 1st International Conference on Advanced Intelligent System and Informatics (AISI2015), November 28-30, 2015, Beni Suef, Egypt*. 2016. p. 183–193. Disponível em: <https://doi.org/10.1007/978-3-319-26690-9_17>. Citado na página 26.6 Citado 1 vezes nas páginas 26.
- 223 GABER, T. et al. Plant identification: Two dimensional-based vs. one dimensional-based feature extraction methods. In: SPRINGER. *10th international conference on soft computing models in industrial and environmental applications*. 2015. p. 375–385. Disponível em: <<https://doi.org/10.1016/j.jal.2016.11.021>>.
- 224 THARWAT, A. et al. Plants identification using feature fusion technique and bagging classifier. In: SPRINGER. *The 1st International Conference on Advanced Intelligent System and Informatics (AISI2015), November 28-30, 2015, Beni Suef, Egypt*. 2016. p. 461–471. Disponível em: <<https://doi.org/>>. Citado na página 26.6 Citado 1 vezes nas páginas 26.
- 225 THARWAT, A.; GABER, T.; HASSANIEN, A. E. One-dimensional vs. two-dimensional based features: Plant identification approach. *Journal of Applied Logic*, Elsevier, v. 24, p. 15–31, 2017. Disponível em: <<https://doi.org/10.1016/j.jal.2016.11.021>>. Citado na página 26.6 Citado 1 vezes nas páginas 26.
- 226 SHARMA, A. et al. Null space based feature selection method for gene expression data. *International Journal of Machine Learning and Cybernetics*, Springer, v. 3, n. 4, p. 269–276, 2012. Disponível em: <<https://doi.org/10.1007/s13042-011-0061-9>>.
- 227 LU, J.; PLATANIOTIS, K. N.; VENETSANOPOULOS, A. N. Regularized discriminant analysis for the small sample size problem in face recognition. *Pattern recognition letters*, Elsevier, v. 24, n. 16, p. 3079–3087, 2003. Disponível em: <[https://doi.org/10.1016/S0167-8655\(03\)00167-3](https://doi.org/10.1016/S0167-8655(03)00167-3)>.
- 228 SHARMA, A.; PALIWAL, K. K. Linear discriminant analysis for the small sample size problem: an overview. *International Journal of Machine Learning and Cybernetics*, Springer, v. 6, n. 3, p. 443–454, 2015. Disponível em: <<https://doi.org/10.1007/s13042-013-0226-9>>. Citado na página 26.6 Citado 1 vezes nas páginas 26.
- 229 SEAL, A. et al. A comparative study of human thermal face recognition based on haar wavelet transform (hwt) and local binary pattern (lbp). *arXiv preprint arXiv:1309.1009*, 2013. Disponível em: <<https://doi.org/10.48550/arXiv.1309.1009>>. Citado na página 27.6 Citado 1 vezes nas páginas 27.
- 230 TAN, A. C.; GILBERT, D. Ensemble machine learning on gene expression data for cancer classification. *Applied bioinformatics*, v. 2, n. 3 Suppl, p. S75–S83, 2003. Citado na página 27.6 Citado 1 vezes nas páginas 27.
- 231 LI, J.; WONG, L. Using rules to analyse bio-medical data: a comparison between c4. 5 and pcl. In: SPRINGER. *International Conference on Web-Age Information Management*. [S.l.], 2003. p. 254–265. Citado na página 27.6 Citado 1 vezes nas páginas 27.
- 232 VAPNIK, V. *The nature of statistical learning theory*. Springer science & business media, 1999. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/211359>>. Citado na página 27.6 Citado 1 vezes nas páginas 27.
- 233 WANG, Z.; YAO, L.; CAI, Y. Rolling bearing fault diagnosis using generalized refined composite multiscale sample entropy and optimized support vector machine. *Measurement*, Elsevier, v. 156, p. 107574, 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107574>>.
- 234 MERCER, J. Xvi. functions of positive and negative type, and their connection the theory of integral equations. *Philosophical transactions of the royal society of London. Series A, containing papers of a mathematical or physical character*, The Royal Society London, v. 209, n. 441-458, p. 415–446, 1909. Citado na página 28.6 Citado 1 vezes nas páginas 28.
- 235 SMOLA, A. J. et al. Introduction to large margin classifiers. MIT Press, 2000. Citado na página 28.6 Citado 1 vezes nas páginas 28.
- 236 HEARST, M. A. et al. Support vector machines. *IEEE Intelligent Systems and their applications*, IEEE, v. 13, n. 4, p. 18–28, 1998. Disponível em: <<https://doi.org/https://doi.org/10.1109/5254.708428>>. Citado na página 28.6 Citado 1 vezes nas páginas 28.

- 237 CHAU, A. L.; LI, X.; YU, W. Support vector machine classification for large datasets using decision tree and fisher linear discriminant. *Future Generation Computer Systems*, Elsevier, v. 36, p. 57–65, 2014. Disponível em: <<https://doi.org/10.1016/j.future.2013.06.021>>. Citado na página 29.6 Citado 1 vezes nas páginas 29.
- 238 LI, X.; CERVANTES, J.; YU, W. Fast classification for large data sets via random selection clustering and support vector machines. *Intelligent Data Analysis*, IOS Press, v. 16, n. 6, p. 897–914, 2012. Disponível em: <<https://doi.org/10.3233/IDA-2012-00558>>. Citado na página 29.6 Citado 1 vezes nas páginas 29.
- 239 ZHENG, X.; ZHANG, L.; YAN, L. Ctsvm: A robust twin support vector machine with correntropy-induced loss function for binary classification problems. *Information Sciences*, v. 559, p. 22–45, 2021. ISSN 0020-0255. Disponível em: <<https://doi.org/10.1016/j.ins.2021.01.006>>. Citado na página 29.6 Citado 1 vezes nas páginas 29.
- 240 HASTIE, T. et al. *The elements of statistical learning: data mining, inference, and prediction*. [S.l.]: Springer, 2009. v. 2. Citado na página 29.6 Citado 1 vezes nas páginas 29.
- 241 CRISTIANINI, N.; SHAW-ETAYLOR, J. *An introduction to support vector machines and other kernel-based learning methods*. [S.l.]: Cambridge university press, 2000. Citado na página 29.6 Citado 1 vezes nas páginas 29.
- 242 AGARWAL, R.; RAMAN, B.; MITTAL, A. Hand gesture recognition using discrete wavelet transform and support vector machine. In: *2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)*. [s.n.], 2015. p. 489–493. Disponível em: <<https://doi.org/10.1109/SPIN.2015.7095326>>. Citado na página 30.6 Citado 1 vezes nas páginas 30.
- 243 TRIBHUVANAM, S.; NAGARAJ, H.; NAIDU, V. Analysis and classification of ecg beat based on wavelet decomposition and svm. *Indian Journal of Science and Technology*, v. 13, n. 24, p. 2404–2417, 2020. Disponível em: <<https://doi.org/10.17485/IJST/v13i24.452>>. Citado na página 30.6 Citado 1 vezes nas páginas 30.
- 244 SANTOS, A. D. et al. Simulador de ruído de cavitação de embarcações utilizando uma rede neural realimentada. In: SBIC. *Anais do 15 Congresso Brasileiro de Inteligência Computacional*. [S.l.], 2021. p. 1–8.
- 245 SANTOS-DOMÍNGUEZ, D. et al. Shipsear: An underwater vessel noise database. *Applied Acoustics*, Elsevier, v. 113, p. 64–69, 2016. Disponível em: <<https://doi.org/10.1016/j.apacoust.2016.06.008>>.
- 246 IPQM. *ETAS 2018 Contest Dataset, as part of the XIII Brazilian Underwater Acoustics Technology Meeting, Rio de Janeiro, Brazil, 2018*. accessed: 05.11.2018. Disponível em: <<https://www.marinha.mil.br/ipqm/etas>>.
- 247 SANTOS-DOMÍNGUEZ, D. et al. *Online ShipsEAR database*. 2017. Available at :<<http://atlanttic.uvigo.es/underwaternoise/>>.
- 248 SOLUTIONS, M. E. *Basic principles of ship propulsion*. accessed: 03.05.2022. Disponível em: <https://www.man-es.com/docs/default-source/marine/tools/basic-principles-of-ship-propulsion_web_links.pdf>. Citado na página 42.6 Citado 1 vezes nas páginas 42.
- 249 LI, Y. et al. A new underwater acoustic signal denoising technique based on ceemdan, mutual information, permutation entropy, and wavelet threshold denoising. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 20, n. 8, p. 563, 2018. Disponível em: <<https://doi.org/10.3390/e20080563>>. Citado na página 45.6 Citado 1 vezes nas páginas 45.
- 250 OU, H.; ALLEN, J. S.; SYRMOS, V. L. Frame-based time-scale filters for underwater acoustic noise reduction. *IEEE Journal of oceanic engineering*, IEEE, v. 36, n. 2, p. 285–297, 2011. Disponível em: <<https://doi.org/10.1109/JOE.2011.2130190>>. Citado na página 45.6 Citado 1 vezes nas páginas 45.
- 251 GREINER, M.; PFEIFFER, D.; SMITH, R. Principles and practical application of the receiver-operating characteristic analysis for diagnostic tests. *Preventive veterinary medicine*, Elsevier, v. 45, n. 1-2, p. 23–41, 2000. Disponível em: <[https://doi.org/10.1016/S0167-5877\(00\)00115-X](https://doi.org/10.1016/S0167-5877(00)00115-X)>. Citado na página 49.6 Citado 1 vezes nas páginas 49.

- 252 BERGMEIR, C.; BENÍTEZ, J. M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*, Elsevier, v. 191, p. 192–213, 2012. Disponível em: <<https://doi.org/10.1016/j.ins.2011.12.028>>. Citado na página 51.6 Citado 1 vezes nas páginas 51.
- 253 RILLING, G.; NAHRSTAEDT, H. *Empirical Mode Decomposition Toolbox*. 2014. Disponível em: <<http://perso.ens-lyon.fr/patrick.flandrin/emd.html>>. Citado na página 55.6 Citado 1 vezes nas páginas 55.
- 254 WANG, K. H. Y.-H.; LO, M.-T. *Uniform Phase Empirical Mode Decomposition Toolbox*. 2018. Disponível em: <<http://in.ncu.edu.tw/mzlo/drLo.html>>. Citado na página 55.6 Citado 1 vezes nas páginas 55.
- 255 EIMSKIP. accessed: 09.03.2017. Disponível em: <<https://logisticsinvietnam.vn/vessel-fleets/>>. Citado na página 65.6 Citado 1 vezes nas páginas 65.
- 256 AS, F. G. . P. accessed: 09.03.2017. Disponível em: <https://epub.ekh.no/f/finnoy_gear_propeller/hovedkatalog/files/assets/common/downloads/FinnHovedbrosjyre%20-%20.pdf>. Citado na página 65.6 Citado 1 vezes nas páginas 65.
- 257 WANG, J. et al. Composite fault diagnosis of gearbox based on empirical mode decomposition and improved variational mode decomposition. *Journal of Low Frequency Noise, Vibration and Active Control*, SAGE Publications Sage UK: London, England, v. 40, n. 1, p. 332–346, 2021. Disponível em: <<https://doi.org/10.1177/1461348420908364>>.
- 258 LI, G.; CHANG, W.; YANG, H. A new hybrid model for underwater acoustic signal prediction. *Complexity*, Hindawi, v. 2020, 2020. Disponível em: <<https://doi.org/10.1155/2020/5167469>>.
- 259 ZHANG, X. et al. A parameter-adaptive vmd method based on grasshopper optimization algorithm to analyze vibration signals from rotating machinery. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 58–72, 2018. Disponível em: <<https://doi.org/10.1016/j.ymssp.2017.11.029>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 260 MIAO, Y.; ZHAO, M.; LIN, J. Identification of mechanical compound-fault based on the improved parameter-adaptive variational mode decomposition. *ISA transactions*, Elsevier, v. 84, p. 82–95, 2019. Disponível em: <<https://doi.org/10.1016/j.isatra.2018.10.008>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 261 WANG, Z.; WANG, J.; DU, W. Research on fault diagnosis of gearbox with improved variational mode decomposition. *Sensors*, MDPI, v. 18, n. 10, p. 3510, 2018. Disponível em: <<https://doi.org/10.3390/s18103510>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 262 LI, Z. et al. Independence-oriented vmd to identify fault feature for wheel set bearing fault diagnosis of high speed locomotive. *Mechanical systems and signal processing*, Elsevier, v. 85, p. 512–529, 2017. Disponível em: <<https://doi.org/10.1016/j.ymssp.2016.08.042>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 263 YAN, X.; JIA, M.; XIANG, L. Compound fault diagnosis of rotating machinery based on ovmd and a 1.5-dimension envelope spectrum. *Measurement Science and Technology*, IOP Publishing, v. 27, n. 7, p. 075002, 2016. Disponível em: <<https://doi.org/10.1088/0957-0233/27/7/075002>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 264 WANG, Z. et al. Application of parameter optimized variational mode decomposition method in fault diagnosis of gearbox. *Ieee Access*, IEEE, v. 7, p. 44871–44882, 2019. Disponível em: <<https://doi.org/10.1109/ACCESS.2019.2909300>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 265 ZHANG, C. et al. A novel intelligent fault diagnosis method based on variational mode decomposition and ensemble deep belief network. *IEEE Access*, IEEE, v. 8, p. 36293–36312, 2020. Disponível em: <<https://doi.org/10.1109/ACCESS.2020.2969412>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 266 ZHANG, Y. et al. Short-term wind speed prediction model based on ga-ann improved by vmd. *Renewable Energy*, Elsevier, v. 156, p. 1373–1388, 2020. Disponível em: <<https://doi.org/10.1016/j.renene.2019.12.047>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.

- 267 LI, G.; ZHENG, M.; YANG, H. Cycle analysis method of tree ring and solar activity based on variational mode decomposition and hilbert transform. *Advances in Meteorology*, Hindawi, v. 2019, 2019. Disponível em: <<https://doi.org/10.1155/2019/1715673>>. Citado na página 130.6 Citado 1 vezes nas páginas 130.
- 268 BOASHASH, B.; O'SHEA, P. A methodology for detection and classification of some underwater acoustic signals using time-frequency analysis techniques. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 38, n. 11, p. 1829–1841, 1990. Disponível em: <<https://doi.org/10.1109/29.103085>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 269 LI, Y.-X. et al. Feature extraction of ship-radiated noise based on permutation entropy of the intrinsic mode function with the highest energy. *Entropy*, MDPI, v. 18, n. 11, p. 393, 2016. Disponível em: <<https://doi.org/10.3390/e18110393>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 270 BANDT, C.; POMPE, B. Permutation entropy: a natural complexity measure for time series. *Physical review letters*, APS, v. 88, n. 17, p. 174102, 2002. Disponível em: <<https://doi.org/10.1103/PhysRevLett.88.174102>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 271 ZHENG, J.; CHENG, J.; YANG, Y. Partly ensemble empirical mode decomposition: An improved noise-assisted method for eliminating mode mixing. *Signal Processing*, Elsevier, v. 96, p. 362–374, 2014. Disponível em: <<https://doi.org/10.1016/j.sigpro.2013.09.013>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 272 LI, Y. et al. A new underwater acoustic signal denoising technique based on ceemdan, mutual information, permutation entropy, and wavelet threshold denoising. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 20, n. 8, p. 563, 2018. Disponível em: <<https://doi.org/10.3390/e20080563>>.
- 273 NUNES, R. R.; ALMEIDA, M. P. d.; SLEIGH, J. W. Entropia espectral: um novo método para adequação anestésica. *Revista Brasileira de Anestesiologia*, SciELO Brasil, v. 54, p. 404–422, 2004. Disponível em: <<https://doi.org/10.1590/S0034-70942004000300013>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 274 HU, G.; WANG, K.; LIU, L. Detection line spectrum of ship radiated noise based on a new 3d chaotic system. *Sensors*, MDPI, v. 21, n. 5, p. 1610, 2021. Disponível em: <<https://doi.org/10.3390/s21051610>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.
- 275 PAN, Y.; CHEN, J.; LI, X. Spectral entropy: A complementary index for rolling element bearing performance degradation assessment. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, SAGE Publications Sage UK: London, England, v. 223, n. 5, p. 1223–1231, 2009. Disponível em: <<https://doi.org/10.1243/09544062JMES1224>>. Citado na página 131.6 Citado 1 vezes nas páginas 131.

Apêndices

APÊNDICE A – Trabalhos Publicados

Neste apêndice são apresentados os trabalhos científicos publicados durante o desenvolvimento desta pesquisa. Os trabalhos estão em ordem cronológica, iniciando pelo mais antigo.

A.1 Artigos aprovados em Congressos

1. *Elio Pithon Sarno Filho, Antônio C. L. Fernandes Jr., Eduardo F. Simas F^o, José M. Seixas, Natanael N. Moura. **Processamento de Sinais de SONAR Passivo usando a Decomposição Empírica em Modos**. XXXVI SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS. Campina Grande - PB, Setembro de 2018. DOI: [10.14209/sbrt.2018.162](https://doi.org/10.14209/sbrt.2018.162)*

Resumo:

Este artigo apresenta a fundamentação teórica de uma nova técnica, a Transformada Hilbert-Huang (HHT), proposta como modificação da análise DEMON, tradicionalmente utilizada no processamento de sinais de SONAR passivo. Também são apresentados resultados preliminares da aplicação da nova técnica a um sinal simulado de SONAR passivo, correspondente ao ruído de cavitação produzido por uma embarcação com frequência de rotação do hélice de 60 rpm e quatro pás. Por apresentar uma relação sinal/ruído (SNR) cerca de 18 dB maior e resolução espectral 50% maior do que as obtidas com a análise DEMON, o novo método demonstrou ter uma maior eficiência quando comparado ao método tradicional.

2. *Elio Pithon Sarno Filho, Antônio C. L. Fernandes Jr., Eduardo F. Simas F^o, José M. Seixas, Natanael N. Moura. **Métodos de Estimação de Frequências para Sinais de SONAR Passivo**. VIII CONFERÊNCIA NACIONAL EM COMUNICAÇÕES, REDES E SEGURANÇA DA INFORMAÇÃO. Salvador - BA, Outubro de 2018.*

Resumo:

Neste trabalho são apresentados os resultados obtidos no estudo e avaliação de diferentes métodos de análise espectral para a detecção e processamento de sinais de SONAR passivo. Os métodos avaliados foram aplicados a um sinal experimental adquirido por um sistema de SONAR passivo real instalado em um submarino da Marinha do Brasil [1]. Em uma avaliação preliminar, e considerando uma análise de banda estreita, os métodos de alta resolução denominados Decomposição em Autovetores e MUSIC apresentaram melhor desempenho do que o Periodograma Modificado, método em que se baseia a análise DEMON tradicional, com grau de vazamento espectral cerca de 12 dB maior, resolução espectral seis vezes maior e relação sinal/ruído (SNR)

pelo menos 5,6 dB maior, se revelando, portanto, potencialmente mais eficientes.

3. *Elio Pithon Sarno Filho, Anderson Damacena Santos, Eduardo F. Simas F^o, Antônio C. L. Fernandes Jr., Natanael N. Moura, José M. Seixas. Análise de Banda Estreita de Sinais de Sonar Passivo Utilizando a Decomposição Empírica em Modos. XIII ENCONTRO DE TECNOLOGIA EM ACÚSTICA SUBMARINA.* Rio de Janeiro - RJ, Novembro de 2018.

Resumo:

Neste trabalho foi apresentada a fundamentação teórica do novo método de análise espectral de sinais de SONAR passivo baseado na Transformada Hilbert-Huang (HHT), com suas variações Decomposição Empírica em Modos (EMD), Decomposição Empírica do Conjunto em Modos (EEMD) e Decomposição Empírica do Conjunto em Modos Completa com Ruído Adaptativo (CEEMDAN). Também foram apresentados os resultados preliminares obtidos pela aplicação do novo método a sinais experimentais de SONAR passivo disponibilizados para o evento pelo Instituto de Pesquisas da Marinha (IPqM) e a sinais simulados com base nestes sinais experimentais. Os resultados apresentados apontam para uma maior acuidade e eficiência, quando comparados aos obtidos pela análise DEMON tradicional, baseada na Transformada de Fourier de Tempo Curto (STFT). A variação CEEMDAN da HHT foi a que apresentou o melhor desempenho, com um desvio percentual médio de frequência de 0,2% e uma resolução em frequência cerca de 50% maior do que a obtida com a DEMON tradicional.

Este trabalho foi agraciado com o 2º lugar no **Prêmio Talentos ETAS**, concedido aos melhores trabalhos desenvolvidos por alunos de pós-graduação na área de Acústica Submarina, e apresentados no *XIII Encontro de Tecnologia em Acústica Submarina*.

4. *Elio Pithon Sarno Filho, Anderson Damacena Santos, Eduardo F. Simas F^o, Antônio C. L. Fernandes Jr., Natanael N. Moura, José M. Seixas. Comparação entre Métodos de Estimção da Densidade Espectral de Potência Aplicados à Análise DEMON. XIII ENCONTRO DE TECNOLOGIA EM ACÚSTICA SUBMARINA.* Rio de Janeiro - RJ, Novembro de 2018.

Resumo:

Neste trabalho são apresentados os resultados obtidos no estudo e avaliação de diferentes métodos de estimção espectral para a detecção e processamento de sinais de SONAR passivo. Os métodos foram aplicados a sinais experimentais disponibilizados para o evento pelo Instituto de Pesquisas da Marinha (IPqM) e a sinais simulados com base nestes sinais experimentais. Em uma avaliação preliminar, e considerando uma análise de banda estreita, os métodos de alta resolução denominados Decomposição em Autovetores e MUSIC apresentaram parâmetros de

desempenho relativos à resolução espectral e à relação sinal/ruído (SNR) cerca de três vezes melhores do que os da análise DEMON tradicional, que se baseia na Transformada de Fourier de Tempo Curto (STFT).

5. *Elio Pithon Sarno Filho, Anderson D. Santos, Eduardo F. Simas F^o, Antônio C. L. Fernandes Jr., José M. Seixas. Transformada de Hilbert-Huang Modificada com Redução do Ruído para Sinais de Sonar Passivo. XXXIX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS. Fortaleza - CE, Setembro de 2021. DOI: [10.14209/sbrt.2021.1570727247](https://doi.org/10.14209/sbrt.2021.1570727247)*

Resumo:

O presente trabalho propõe um método de análise TF para sinais de SONAR passivo baseado na HHT/EMD, denominado HHT-modificada, no qual a redução de ruído é realizada a partir da análise da função de autocorrelação (ACF) e da filtragem wavelet com limiar (WTD), aplicados após a EMD. Nessa nova estratégia, as funções de modo intrínseco (IMFs) resultantes da decomposição UPEMD (variante da EMD) são classificadas como IMF-R (contendo apenas ruído) ou IMF-T (IMF de transição, composta de sinal de interesse e ruído), com base no valor da ACF. Após a separação, as IMF-R são descartadas e as IMF-T são tratadas pela WTD para redução de ruído. Os resultados obtidos com sinais experimentais de SONAR passivo são utilizados para validar o método proposto e indicam um melhor desempenho em relação à análise DEMON padrão.

6. *Anderson Damacena Santos, Elio P. Sarno F^o, Eduardo F. Simas F^o, Antônio C. L. Fernandes Jr., José M. Seixas. Simulador de Ruído de Cavitação de Embarcações utilizando uma Rede Neural Realimentada. XV CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL. Joinville - SC, Outubro de 2021. DOI: [10.21528/CBIC2021-145](https://doi.org/10.21528/CBIC2021-145)*

Resumo:

Sistemas de sonar passivo são utilizados, tanto em aplicações civis, quanto militares, para a realização de tarefas como monitoramento do ambiente submarino e detecção de animais e embarcações. A aquisição de sinais acústicos submarinos (UAS) requer um complexo sistema de medição e envolve custos consideráveis para instalação e manutenção. Aliado a isso, a grande variedade de classes de embarcações e condições climáticas, aumenta consideravelmente a diversidade desse tipo de sinais. Nesse contexto, o presente trabalho propõe-se a desenvolver um simulador de sinais acústicos submarinos, que combina informações da cavitação de embarcações, com ruído ambiente, utilizando um sistema composto de um bloco fenomenológico e um bloco baseado em aprendizado de máquinas. O primeiro deles produz a combinação entre o ruído de cavitação gerado por embarcações e o 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 ao comportamento de sinais experimentais. O simulador proposto foi capaz de produzir sinais com grande fidedignidade a sinais reais.

A.2 Artigo publicado em revista

7. *Elio Pithon Sarno Filho, Anderson D. Santos, Henrique M. Sinezio, Eduardo F. Simas F^o, Antônio C. L. Fernandes Jr., José M. Seixas. Empirical Mode Decomposition: Theory and Applications in Underwater Acoustics. JOURNAL OF COMMUNICATION AND INFORMATION SYSTEMS, VOL. 37, NO.1. Submetido no dia 15/03/2022, Aceito no dia 03/08/2022. DOI: [10.14209/jcis.2022.16](https://doi.org/10.14209/jcis.2022.16)*

Resumo:

Considering the successful application of EMD to different problems and the importance of underwater acoustic signals (UAS) processing for civilian and military purposes, this work intends to serve as a comprehensive theoretical review of the fundamental aspects of both EMD and HHT. Variations of the original EMD algorithm are also presented, emphasizing those that include modifications for solving limitations such as mode mixing (MM) and noise sensitivity. Among these algorithms, there are the disturbance assisted ones, such as EEMD, CEEMDAN, ICEEMDAN and UPEMD, which usually lead to better results in the analysis of experimental signals. The specific characteristics of some of these methods make them potentially more suitable for application to UAS. As a method suited for time-varying nonlinear signals analysis, HHT/EMD was applied to UAS characterization, particularly considering the passive SONAR framework. Results obtained from simulated and experimental data indicate the advantages of the presented methods: background noise level reduction, time-varying frequency components monitoring, and sharp frequency estimation resolution.

APÊNDICE B – Decomposição em Modos Variacionais

A decomposição em modos variacionais (*variational mode decomposition* – VMD) [198] é um método não-recursivo de decomposição de sinais não-lineares e não estacionários [199] que se baseia na filtragem Wiener, na transformada de Hilbert (HT) e na demodulação heteródina [199, 198, 167]. O princípio básico de funcionamento deste método consiste em decompor, de forma não-recursiva e adaptativa, um sinal multicomponente $x(t)$ em um conjunto de K IMFs de banda limitada [198, 257, 258]. Cada componente IMF u_k ($k = 1, 2, \dots, K$) é definido como um sinal modulado em amplitude e em frequência (AM-FM) [198, 257], concentrado na frequência central ω_k . A representação analítica desse sinal é mostrada na Equação B.1 [198, 167, 257]:

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (\text{B.1})$$

em que $A_k(t)$ e $\phi_k(t)$ são, respectivamente, a amplitude instantânea e a fase da k -ésima IMF $u_k(t)$ [198, 167]. A frequência instantânea $\omega_k(t)$ é obtida pela diferenciação de $\phi_k(t)$. Cada componente $u_k(t)$ é processada pela HT, obtendo-se o sinal analítico $\left[\delta(t) + \frac{j}{\pi t}\right] u_k(t)$, em que $\delta(t)$ é a função impulso unitário. Em seguida, é realizada a demodulação de cada k -ésimo componente analítico, multiplicando-o pelo fator $e^{-j\omega_k t}$, o que resulta no sinal banda base $\left[\left(\delta(t) + \frac{j}{\pi t}\right) u_k(t)\right] e^{-j\omega_k t}$ [198, 167].

A largura da banda de cada k -ésimo componente $u_k(t)$ demodulado pode ser estimada pelo processo de suavização Gaussiana H1 (H1 – *Gaussian smoothness*), definido como o quadrado da segunda norma do gradiente [198, 257]. O problema é equacionado pelo seguinte modelo varacional restrito [198, 167, 257]:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \frac{\partial}{\partial t} \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{sujeito a } \sum_{k=1}^K u_k(t) = x(t) \end{cases} \quad (\text{B.2})$$

Para se obter a solução otimizada da Equação B.2, são aplicados o fator de penalidade α e o multiplicador Lagrangiano λ , obtendo-se a função Lagrangiana aumentada a seguir [198, 167]:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}) = & \alpha \sum_{k=1}^K \left\| \frac{\partial}{\partial t} \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ & + \left\| x(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (\text{B.3})$$

A VMD utiliza o método de alternância de direção do operador de multiplicação (*alternating direction method of multiplication operator* – ADMM) [198, 200, 257] para solucionar iterativamente a Equação B.3, utilizando a condição de parada mostrada na Equação B.4, em que $\hat{u}_k^n$ é o k -ésimo componente IMF estimado na n -ésima iteração e ε é um fator discriminante de acurácia [198, 258]:

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (\text{B.4})$$

Uma vez satisfeita essa condição, o processo iterativo é finalizado e a decomposição do sinal $x(t)$ em K componentes IMFs u_k com frequência central ω_k terá sido completada [198, 167].

Na literatura científica, vários pesquisadores vêm ressaltando a importância da escolha adequada dos parâmetros K (número total de IMFs) e α (fator de penalidade) para o bom desempenho da VMD. Nesse sentido, têm sido propostos algoritmos como a otimização de gafanhotos (*grasshopper optimization algorithm*) [259], a otimização das moscas de frutas (*fruit fly optimization algorithm*) [260], a entropia de permutação (*permutation entropy*–PE) [261] e a pesquisa de pico espectral (*spectral peak search*) [262], para buscar adaptativamente esses parâmetros da VMD. Em [263] e [264], os autores utilizam, respectivamente, um algoritmo genético e um algoritmo multi-objetivo de otimização de enxame de partículas, para determinar os melhores valores de K e α na VMD, visando solucionar o problema de falhas em máquinas rotativas e de diagnóstico de falhas em uma caixa de engrenagens, respectivamente.

Baseado em suas várias vantagens, a VMD tem sido amplamente utilizada em processamento de sinais submarinos [199], diagnóstico de falhas em máquinas [265], predição da velocidade do vento na geração de energia eólica [266]. Em [267], combinando a VMD com a transformada de Hilbert (HT) para analisar dados extraídos de anéis de árvores, o autor provou a influência da atividade das manchas solares no crescimento desses anéis.

APÊNDICE C – Detalhes do Estudo de Caso

3

C.1 Definição dos atributos

À seguir, são relacionados os cinco atributos investigados na presente pesquisa, que possuem como característica comum, a capacidade de distinguir sinais mais ruidosos, daqueles com maior grau de regularidade. Em termos práticos, são utilizados os valores normalizados desses atributos.

- **Função de autocorrelação** (*autocorrelation function* - ACF) - O coeficiente ACF ($\rho_{xx}(\eta)$) é definido em [213]. Os sinais que tem certa regularidade (contendo componentes de frequência significativos) apresentam $0 < |\rho_{xx}(\eta)| < 1$, enquanto sinais com baixa SNR ou ruído puro apresentam $|\rho_{xx}(\eta)| \cong 0$. No caso de sinais aproximadamente senoidais, $|\rho_{xx}(\eta)| \cong 1$. A ACF de um sinal periódico também é periódica, com período igual ao do sinal [213]. Essa propriedade é particularmente interessante na análise de sinais de sonar passivo, por geralmente apresentarem componentes harmônicos múltiplos de uma frequência fundamental (velocidade de rotação do hélice). Em [268], é proposta uma metodologia para a detecção e classificação de UAS, em que a ACF é empregada para determinar o número de cilindros e a taxa de ignição do motor de embarcações;
- **Entropia de permutação** (*permutation entropy* - PE) - Este atributo é uma medida estatística do grau de aleatoriedade ou regularidade de uma série temporal. As etapas do cálculo do seu valor normalizado (PE_{nr}) são apresentadas em [269, 270]. No caso de sinais muito ruidosos, $PE_{nr} \cong 1$, enquanto sinais com crescente regularidade, apresentam $PE_{nr} \cong 0$ [271]. Em [269], é proposto um método de extração de atributos de UAS baseado na PE. Em [270, 272, 271], a PE é utilizada na redução de ruído de UAS;
- **Entropia espectral** (*spectral entropy* - SE) - Este atributo se caracteriza por quantificar a regularidade de um sinal no domínio da frequência [273], sendo utilizado na extração de características espectrais de sinais com baixa SNR, tais como os de sonar passivo [274]. O processo de obtenção do seu valor normalizado (SE_{nr}) é descrito em [275], sendo sua faixa de variação $0 \leq SE_{nr} \leq 1$. Valores de $SE_{nr} \cong 0$ são obtidos para sinais com grau elevado de regularidade, enquanto valores de $SE_{nr} \cong 1$, correspondem a sinais muito ruidosos [273];
- **Taxa de previsibilidade** (*predictivity ratio* - PR) - Este atributo é uma medida da acurácia de predição de um sinal, indicando o seu grau de aleatoriedade. O valor normalizado (PR_{nr}) é definido em [213], variando na faixa $0 \leq PR_{nr} \leq 1$. Valores de $PR \cong 0$, indicam sinais pouco ruidosos, contendo componentes espectrais significativos. Em contrapartida, valores de $PR \cong 1$, são obtidos para sinais fortemente corrompidos pelo ruído, para os quais é mais difícil prever corretamente as amostras;

- **Informação mútua** (*mutual information* - MI) - Este atributo representa uma medida da interdependência estatística entre duas variáveis aleatórias (VAs), sendo definido em [272]. O seu valor normalizado varia na faixa $0 \leq MI_{nr} \leq 1$. Caso as VAs sejam independentes (característica de sinais mais ruidosos), $MI_{nr} \cong 0$. Por outro lado, à medida em que aumenta a interdependência entre elas (caso de sinais mais regulares), o valor de MI_{nr} tende a 1 [272]. Em [272], a MI é utilizada em um método de redução de ruído, para identificar IMF-R produzidas pela decomposição CEEMDAN de sinais acústicos submarinos (UAS).

C.2 Limiar de Seleção da BWTD

A seguir, são apresentadas as etapas da estratégia de ajuste do limiar de seleção da BWTD:

1. Inicialmente, é analisado o caso da filtragem BWTD das IMF-T produzidas pelo seletor de IMFs. Visando facilitar a explicação da estratégia de ajuste, é utilizada, como exemplo ilustrativo, a decomposição UPEMD de um sinal experimental de sonar passivo genérico, em que foram produzidas a IMF-T e a IMF-R com espectros de amplitude mostrados na Figura 56a e Figura 57a, respectivamente. No caso da IMF-T (Figura 56a), é evidente a presença do componente de frequência significativo de 601,3 rpm, que se destaca nitidamente dos demais componentes das bandas laterais de ruído (vide critério 1 do especialista no Apêndice D). Isso não ocorre no caso da IMF-R (Figura 57a), em que o valor de pico do componente de maior amplitude (1243 rpm) é próximo do nível máximo da banda de ruído, não sendo, portanto, considerado um componente-significativo (vide critério 2 do especialista no Apêndice D).

De um modo geral, essa diferença básica entre os espectros da IMF-T e da IMF-R, também pode ser verificada por intermédio do histograma ou do boxplot das distribuições de coeficientes wavelet Bark $S_m[k]$, relativos aos dois tipos de IMF. Com relação ao presente exemplo, são apresentados nas Figuras 56b,c e nas Figuras 57b,c, os histogramas e boxplots resultantes da aplicação da BWTD à IMF-T e à IMF-R, respectivamente. Em ambos os casos, adotou-se a banda de frequência linear $[f_l = 0, f_u = 2500]$ rpm e o número de sub-bandas M igual a 100, sendo as distribuições dos coeficientes $S_m[k]$ relativas à sub-banda de índice $m = 50$.

A análise do histograma e do boxplot das Figuras 56b e 56c, respectivamente, mostra que, no caso da IMF-T, existe uma maior concentração de amostras (*bins*) na região de baixas amplitudes ($\sim [0 - 10]$), que correspondem aos componentes espectrais das bandas laterais de ruído (Figura 56a). Por outro lado, tem-se apenas uma única amostra (com amplitude igual a $\sim 34,4$) correspondente ao componente de frequência significativo de 601,3 rpm, que está bem distanciada (com amplitude cerca de 3,5 vezes maior) das amostras da banda de ruído.

Em relação ao histograma e do boxplot das Figuras 57b e c, respectivamente, tem-se que, no caso da IMF-R, existe apenas uma concentração de amostras (*bins*) na região de baixas amplitudes ($\sim [0 - 15]$), correspondentes aos componentes espectrais da banda de ruído

(Figura 57a). Não existem amostras isoladas, distanciadas da região de ruído, que possam estar eventualmente associadas a um componente de frequência significativo.

As constatações relativas à IMF-T e IMF-R realizadas para esse sinal sonar específico, podem ser generalizadas para outros sinais, tendo em vista a própria definição de IMF-T e IMF-R (vide critérios 1 e 2 do especialista no Apêndice D). Assim sendo, é possível estabelecer um critério geral de ajuste do limiar de seleção Thr_m dos coeficientes wavelet Bark $S_m[k]$ relativos aos componentes-significativos de frequência nas M sub-bandas.

Tendo em vista que as IMFs produzidas pelo seletor de IMFs (Figura ??a) são, à princípio, do tipo IMF-T, elas contem, de maneira geral, componentes-significativos de frequência, exceção feita aos casos em que ocorrerem erros de classificação (falsos positivos). Assim sendo, é possível reduzir o nível de ruído dessas IMFs, ajustando-se o limiar de seleção Thr_m em um valor próximo ao do coeficiente $S_m[k]$ associado ao componente-significativo de maior amplitude.

A Equação C.1 expressa o critério utilizado na escolha do limiar de seleção dos coeficientes wavelet Bark nas M sub-bandas, para o caso da filtragem BWTD aplicada às IMF-T produzidas pelo seletor de IMFs (Figura ??a). No exemplo apresentado, o limiar de seleção foi ajustado em $\text{Thr}_{50} = 31,0$ (Figura 56b), valor este um pouco abaixo daquele associado ao coeficiente do componente-significativo de máxima amplitude (601,3 rpm, na Figura 56a), qual seja, $\max(S_{50}[k]) = 34,4$ (Figuras 56b,c).

$$\text{Thr}_m = \lambda_1 \max(S_m[k]), \quad m = 1, 2, \dots, M \quad (\text{C.1})$$

em que o valor do fator de ajuste λ_1 é escolhido empiricamente na faixa $[0,7 - 1,0]$ e $\max(S_m[k])$ é o valor do coeficiente wavelet Bark da m -ésima sub-banda, relativo ao componente-significativo de maior amplitude. No exemplo apresentado, foi escolhido $\lambda_1 = 0,9$ para as $M = 100$ sub-bandas.

É importante salientar que, caso a IMF produzida pelo seletor de IMFs seja uma IMF-R (ocorrência de um falso positivo), o limiar de seleção Thr_m escolhido com base no critério da Equação C.1, será próximo do componente de maior amplitude contido na banda de ruído. Esse componente é interpretado pelo algoritmo como sendo um componente-significativo e a aplicação da filtragem BWTD a essa IMF-R reduzirá a banda de ruído. No exemplo apresentado, tal componente é o de frequência igual a 1243 rpm (Figura 57a), enquanto $\max(S_{50}[k]) = 14,7$ e o limiar de seleção é $\text{Thr}_{50} = 13,2$.

Figura 56 – Distribuição dos coeficientes wavelet Bark de uma IMF-T na 50ª sub-banda: (a) Espectro de amplitude da IMF-T; (b) Histograma dos coeficientes; (c) Boxplot dos coeficientes.





Figura 57 – Distribuição dos coeficientes wavelet Bark de uma IMF-R na 50ª sub-banda: (a) Espectro de amplitude da IMF-R; (b) Histograma dos coeficientes; (c) Boxplot dos coeficientes.




2. No caso da pré-filtragem BWTD (Figura ??b), considerando-se que o sinal analisado $x[n]$ não é uma IMF, torna-se inviável identificar componentes-significativos presentes nesse sinal. Nesse caso, o critério de escolha do limiar de seleção Thr_m expresso pela Equação C.1 é substituído por aquele da Equação C.2:

$$Thr_m = Q_3^m + \lambda_2 (Q_3^m - Q_1^m), \quad m = 1, 2, \dots, M \quad (C.2)$$

em que Q_1^m e Q_3^m são, respectivamente, o 1º e o 3º quartis da distribuição dos coeficientes wavelet Bark do sinal analisado $x[n]$ na m -ésima sub-banda. O valor do fator de ajuste λ_2 é escolhido empiricamente na faixa $(Q_3^m / (Q_1^m - Q_3^m)) < \lambda_2 < \infty$. No exemplo apresentado, para $\lambda_2 = 1,5$, obtém-se o limiar de seleção $Thr_{50} = 13,2$ (Figura 58a), a partir dos valores Q_1^{50} e Q_3^{50} indicados na Figura 58b.

Figura 58 – Distribuição dos coeficientes wavelet Bark do sinal analisado $x[n]$ na 50ª sub-banda.: (a) Histograma dos coeficientes; (b) Boxplot dos coeficientes.



C.3 Faixas dos Parâmetros Operacionais

À seguir, são apresentados os procedimentos realizados para a fixação das faixas de valores dos parâmetros operacionais (hiperparâmetros), utilizados no processo de seleção dos limiares de classificação:

1. O parâmetro operacional de pré-filtragem BWTD é escolhido na faixa $\lambda_2 = [-2 : 1 : 2]$, empiricamente fixada;
2. A faixa de valores do parâmetro operacional OL (fator de sobreposição entre janelas adjacentes) investigada, engloba praticamente toda aquela teoricamente possível ($0 \leq OL < 1$). A faixa definida foi $OL = [0 : 0, 1 : 0, 9]$;
3. A faixa de variação do parâmetro operacional FD foi determinada conforme se segue. Considerando a estrutura de quadros J_{ik} , com largura da janela de análise WS e fator de sobreposição OL entre janelas adjacentes, têm-se que o número total de quadros N_J é dado pela Equação C.3:

$$N_J = \frac{N_s}{(1 - OL)WS}, \quad 0 \leq OL < 1 \quad (C.3)$$

Tendo em vista que o número total de amostras do sinal analisado $x[n]$ é $N_s = 10^4$ (Seção 3.1) e fixando-se o número máximo de janelas utilizado no presente trabalho em $N_{J_{\max}} = 10^3$, tem-se que, nessa condição limite, os valores mínimo e máximo da largura de janela¹ são, respectivamente, $\widehat{WS}_{\min} = 10$ (correspondente a $OL = 0$) e $\widehat{WS}_{\max} = 10^2$ (correspondente a $OL = 0, 9$).

¹ As notações $\widehat{WS}_{\min}$ e $\widehat{WS}_{\max}$ são adotadas para representar os valores limites da largura de janela na condição específica de $N_{J_{\max}} = 10^3$, reservando as notações $WS_{\min}$ e $WS_{\max}$ para designar os valores limites do parâmetro WS de uma forma geral.

Substituindo cada um desses dois valores limites na Equação C.4, que explicita o número de amostras/janela da i -ésima IMF ($\text{NAJ}^{(i)}$) em função do fator de decimação da IMF anterior ($\text{FD}^{(i-1)}$), e impondo-se o critério de obter, após a subamostragem, o número mínimo de amostras/janela da IMF5 igual a 8 ($\text{NAJ}^{(5)} \geq 8$), determina-se os valores limites da faixa de variação de FD:

$$\text{NAJ}^{(i)} = \text{WS} \times [\text{FD}^{(i-1)}] \quad (\text{C.4})$$

$$\text{FD}_{\min} = \sqrt[4]{\frac{8}{\widehat{\text{WS}}_{\max}}} = \sqrt[4]{\frac{8}{10^2}} \cong 0.53 \quad (\text{C.5})$$

$$\text{FD}_{\max} = \sqrt[4]{\frac{8}{\widehat{\text{WS}}_{\min}}} = \sqrt[4]{\frac{8}{10}} \cong 0.94 \quad (\text{C.6})$$

Tem-se, portanto, que a faixa de variação adotada para esse parâmetro operacional é $\text{FD} = [0,5 : 0,9]$;

4. No caso da faixa de variação do parâmetro operacional WS, foram considerados, para o cálculo de $\text{WS}_{\max}$, o valor limite $\text{OL} = 0$ e $N_{\text{Jmin}} = 2$, escolhido empiricamente. Utilizando a Equação C.3, tem-se $\text{WS}_{\max} = 4000$. Com relação a $\text{WS}_{\min}$, considerou-se a situação limite em que $\text{OL} = 0,9$ e $N_{\text{Jmax}} = 200$, valor esse também fixado empiricamente. Utilizando a Equação C.3, tem-se que $\text{WS}_{\min} = 500$.

Portanto, a faixa de variação desse parâmetro operacional é $\text{WS} = [500 : 10 : 4000]$;

5. No caso do atributo $\rho_{xx}(\eta)$ (coeficiente ACF), a faixa de LAGs $[\eta_{\min} : \eta_{\max}]$ foi fixada empiricamente em $\eta_{\min} = 10$ e $\eta_{\max} = [100 : 50 : 450]$;

APÊNDICE D – Gabarito Especialista

A seguir, são apresentados os quatro critérios adotados pelo especialista para a construção do gabarito (padrão-ouro), usado no treinamento e validação dos classificadores SVM e FDA. Basicamente, o processo consistiu na separação das 200 IMFs, relativas ao conjunto de 40 sinais experimentais (Seção 3.1), em duas classes (IMF-T e IMF-R), tendo por base esses critérios.

Visando uma melhor compreensão do que é exposto, nos referimos às Figuras 59 e 60, ilustrativas das 5 primeiras IMFs e da PSD média normalizada $\bar{P}(f)$ resultante da aplicação da análise a um sinal experimental genérico. O gabarito final resultante dessa análise é apresentado na Tabela 24.

1. Uma dada IMF deve possuir pelo menos um componente-significativo para ser considerada IMF-T. Ou seja, deve possuir um componente de frequência que se distingue em relação à banda de ruído da IMF. Como é mostrado na Figura 59, a IMF3 é a única que não atende a este requisito, sendo por isso considerada uma IMF-R. Todas as demais IMFs possuem pelo menos um componente-significativo H_i ($i = 1, 2, \dots, 6$), podendo ser classificadas como IMF-T, caso atendam aos demais critérios de classificação;
2. O valor de pico de pelo menos um componente-significativo H_i da IMF deve estar acima do nível máximo da banda de ruído para que ela seja classificada como IMF-T. Na Figura 59, o componente H_5 não satisfaz a este requisito, ao contrário de todos os demais componentes indicados. Como a IMF4 possui apenas esse componente-significativo, ela é classificada como IMF-R;
3. São consideradas IMF-Ts, as IMFs com pelo menos um componente-significativo possuindo frequência próxima (diferença menor ou igual a 10 rpm) a de um dos componentes de frequência da PSD média normalizada $\bar{P}(f)$ resultante da aplicação da análise DEMON ao sinal gerador da IMF em questão. Esses componentes são denominados, na presente análise, como componentes-referência. Conforme ilustrado na Figura 60, os componentes-referência são aqueles com valor de pico acima do limiar de seleção y_{LIM} , valor esse fixado em 3 dB acima do nível médio de ruído de fundo (NMR). Nessa figura, tem-se que os componentes-referência são os que possuem amplitudes y_1 a y_7 ;
4. São consideradas IMF-Ts, as IMFs com pelo menos um componente-significativo possuindo frequência dentro da faixa de interesse, que é delimitada pelos valores mínimo e máximo de frequência dos componentes-referência, relativos à PSD média normalizada $\bar{P}(f)$ resultante da aplicação da análise DEMON ao sinal gerador da IMF em questão.

Figura 59 – Conjunto de IMFs relativas a um sinal experimental genérico, com indicação dos componentes-significativos H_i ($i = 1, 2, \dots, 6$).




Figura 60 – Conjunto de IMFs relativas a um sinal experimental genérico, com indicação dos componentes-referência, que apresentam amplitudes y_i dB/rpm ($i = 1, 2, \dots, 7$).





Tabela 24 – Gabarito final (padrão-ouro) resultante da análise realizada pelo especialista.

sinal	IMF1	IMF2	IMF3	IMF4	IMF5
1	IMF-R	IMF-T	IMF-T	IMF-R	IMF-R
2	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
3	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
4	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
5	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
6	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
7	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
8	IMF-R	IMF-R	IMF-R	IMF-T	IMF-R
9	IMF-T	IMF-R	IMF-T	IMF-T	IMF-R
10	IMF-R	IMF-R	IMF-T	IMF-T	IMF-R
11	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
12	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
13	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
14	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
15	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
16	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
17	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
18	IMF-T	IMF-T	IMF-T	IMF-T	IMF-T
19	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
20	IMF-R	IMF-R	IMF-R	IMF-R	IMF-R

 IMF-T

sinal	IMF1	IMF2	IMF3	IMF4	IMF5
21	IMF-R	IMF-R	IMF-R	IMF-R	IMF-R
22	IMF-R	IMF-R	IMF-R	IMF-R	IMF-R
23	IMF-R	IMF-R	IMF-R	IMF-R	IMF-R
24	IMF-T	IMF-T	IMF-T	IMF-T	IMF-R
25	IMF-R	IMF-T	IMF-T	IMF-T	IMF-R
26	IMF-R	IMF-R	IMF-T	IMF-R	IMF-R
27	IMF-R	IMF-R	IMF-R	IMF-T	IMF-R
28	IMF-T	IMF-T	IMF-T	IMF-T	IMF-T
29	IMF-R	IMF-T	IMF-R	IMF-T	IMF-T
30	IMF-R	IMF-T	IMF-T	IMF-R	IMF-T
31	IMF-R	IMF-T	IMF-T	IMF-R	IMF-R
32	IMF-R	IMF-T	IMF-T	IMF-T	IMF-R
33	IMF-T	IMF-T	IMF-T	IMF-R	IMF-T
34	IMF-T	IMF-R	IMF-T	IMF-T	IMF-R
35	IMF-T	IMF-T	IMF-T	IMF-R	IMF-T
36	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
37	IMF-R	IMF-T	IMF-T	IMF-T	IMF-T
38	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
39	IMF-T	IMF-T	IMF-T	IMF-R	IMF-R
40	IMF-R	IMF-R	IMF-T	IMF-R	IMF-R

 IMF-R