



Universidade Federal da Bahia
Escola Politécnica
Departamento de Engenharia Elétrica e de Computação
Programa de Pós-Graduação em Engenharia Elétrica

FRANKLIN LIMA SANTOS

**APLICAÇÃO DA TRANSFORMADA DE HILBERT-HUANG EM
ENSAIOS NÃO DESTRUTIVOS COM ULTRASSOM**

DISSERTAÇÃO DE MESTRADO

Salvador
2020

FRANKLIN LIMA SANTOS

**APLICAÇÃO DA TRANSFORMADA DE HILBERT-HUANG EM
ENSAIOS NÃO DESTRUTIVOS COM ULTRASSOM**

Dissertação de Mestrado apresentada ao Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola Politécnica da Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Paulo César Machado de Abreu Farias

Co-orientador: Prof. Dr. Eduardo Furtado de Simas Filho

Salvador
2020

S237 Santos, Franklin Lima.

Aplicação da transformada de Hilbert-Huang em ensaios não destrutivos com ultrassom / Franklin Lima Santos. – Salvador, 2020.

115 f.: il. color.

Orientador: Prof. Dr. Paulo César Machado de Abreu Farias.

Coorientador: Prof. Dr. Eduardo Furtado de Simas Filho.

Dissertação (mestrado) – Universidade Federal da Bahia. Escola Politécnica, 2020.

1. Processamento de Sinais. 2. Ensaios não destrutivos. 3. Ultrassom. 4. Redes Neurais. 5. Transformada de Hilbert-Huang. I. Farias, Paulo César Machado de Abreu. II. Simas Filho, Eduardo Furtado de. III. Universidade Federal da Bahia. IV. Título.

CDD: 006.32

TERMO DE APROVAÇÃO

FRANKLIN LIMA SANTOS


APLICAÇÃO DA TRANSFORMADA DE HILBERT-HUANG EM ENSAIOS NÃO DESTRUTIVOS COM ULTRASSOM

Dissertação de Mestrado aprovada como requisito parcial para obtenção do grau de Mestre em Processamento da Informação e Energia, Universidade Federal da Bahia - UFBA, pela seguinte banca examinadora:



Prof. Dr. Paulo César Machado de Abreu Farias (Orientador)

Doutor em Engenharia Nuclear, Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, COPPE/UFRJ, Brasil
Professor da Universidade Federal da Bahia (UFBA)



Prof. Dr. Eduardo F. de Simas Filho (Co-orientador)

Doutor em Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Brasil
Professor da Universidade Federal da Bahia (UFBA)



Prof. Dr. Antônio Carlos Lopes Fernandes Júnior (Examinador DEEC)

Doutor em Engenharia Elétrica, Universidade Estadual de Campinas, Brasil
Professor da Universidade Federal da Bahia (UFBA)



Prof. Dr. Carmelo Jose Albanez Bastos Filho (Examinador externo)

Doutor em Engenharia Elétrica, Universidade Federal de Pernambuco, Brasil
Professor da Universidade Estadual de Pernambuco (UPE)

Salvador, 7 de dezembro de 2020.

AGRADECIMENTOS

Agradeço imensuravelmente aos meus pais, que nunca negligenciaram o poder da educação como, se não a única, a mais expressiva ferramenta de transformação de realidades. À Dona Aidil e Seu Bira, minha eterna gratidão e amor.

À minha irmã, Fabiane, por ter contribuído imensamente na minha formação pessoal e profissional.

Ao meu companheiro Lucas Stasi, pelo suporte ao longo desses anos e pelo incentivo ao desenvolvimento deste trabalho, mesmo sabendo que muitas horas lhes seriam tomadas.

Aos amigos e amigas do CEFET-BA, que há 13 anos me acompanham nos momentos de alegria e tristeza e que fazem os percalços da vida muito mais serenos.

Aos meus colegas e amigos da Área de Eletrônica Embarcada do SENAI CIMA-TEC, por me proporcionarem um contínuo aprendizado e pela constante troca de experiências.

Por fim, agradeço aos meus orientadores Paulo César e Eduardo Simas, pelo esforço em contribuir e tornar este trabalho uma realidade, aos colegas do Laboratório de Sistemas Digitais (LSD-UFBA) e aos professores do Grupo de Ensaios Não Destrutivos (GPEND-IFBA) pelo suporte e contribuições à este trabalho.

*Insofern sich die Sätze der Mathematik auf die
Wirklichkeit beziehen, sind sie nicht sicher, und insofern
sie sicher sind, beziehen sie sich nicht auf die Wirklichkeit.*

*Se as leis da Matemática referem-se à realidade, elas não
estão corretas; e, se estiverem corretas,
não se referem à realidade.
—Albert Einstein*

RESUMO

A utilização de técnicas de processamento de sinais como auxílio no diagnóstico de falhas em processos de manufatura tem sido bastante promissora, pois permite o aumento da eficiência dos processos, assegura qualidade aos produtos e a segurança das instalações. Este trabalho propõe a utilização da transformada de Hilbert-Huang (THH) como ferramenta de extração de características dos sinais de ultrassom obtidos em ensaio experimental em cordão de solda por meio da técnica TOFD. A THH é uma decomposição tempo-frequência que utiliza funções base de transformação estimadas a partir dos sinais de interesse. Tais funções base são obtidas a partir de algoritmos de decomposição tais como EMD, EEMD e CEEMDAN. Após obtenção dos sinais experimentais e aplicação da THH para extração de características, um classificador baseado em rede neural artificial tipo *perceptron* de múltiplas camadas foi utilizado para indicar o estado do material, e apresentou desempenho satisfatório, alcançando valores de produto das eficiências superiores a 90% em todos os casos analisados. Quando os algoritmos de decomposição usados foram o EEMD e CEEMD, os valores de produto das eficiências foram 98,5% e 97,4%, respectivamente, ao passo que quando o algoritmo EMD foi usado, o valor atingiu o patamar de 95,3%. Quando a THH foi associada a PCA, o classificador conseguiu discriminar as diferentes classes de defeito com eficiência de 91,0% pra THH-EMD, 93,0% para THH-EEMD e 92,7% para THH-CEEMDAN. Esse resultado se mostrou comparável aos obtidos em trabalhos anteriores com outras técnicas de pré-processamento, cujo maiores valores obtidos para um conjunto de dados similar foram 94,8% utilizando a DFT e 97,5% para DFT com PCA.

Palavras-chave: Inspeção por Ultrassom, TOFD, Ensaio não destrutivo, Transformada de Hilbert-Huang, Modelos não-lineares, Decomposição empírica em modos, redes neurais.

ABSTRACT

The use of digital signal processing as an aid for diagnosing failures in manufacturing processes has been very promising, as it allows to increase the efficiency of such processes and ensures product quality and the safety of installations. This work proposes the use of Hilbert-Huang transform (HHT) as a tool for feature extraction of ultrasound signals obtained in an experimental procedure on welded joints using the TOFD technique. HHT is a time-frequency decomposition that uses base functions for transformation that are estimated from the signals of interest. Such base functions are obtained from decomposition algorithms such as EMD, EEMD and CEEMDAN. Once the experimental signals were obtained and the HHT applied for feature extraction, a classifier based on multilayer perceptron neural network was used and showed a satisfactory performance, reaching efficiency product above 90% in all considered cases. When EEMD and CEEMDAN were used as decomposition algorithms, the efficiency product achieved 98.5% and 97.4%, respectively, whereas the EMD algorithm was used, the value reached 95.3%. When HHT was associated with PCA, the classifier was able to discriminate the different defect classes with 91.0% for HHT-EMD, 93.0% for HHT-EEMD and 92.7% for HHT-CEEMDAN. These results are comparable to those found in the literature in which use other pre-processing techniques, whose highest values obtained for a similar dataset were 94.8% using the DFT and 97.5% for DFT with PCA.

Keywords: Ultrasound testing, TOFD, Non-Destructive Testing, Hilbert-Huang Transform, Non-linear models, Empirical Mode Decomposition, Neural Networks.

LISTA DE FIGURAS

2.1	Ilustração da técnica TOFD.	10
2.2	Equipamento que permite a aplicação da técnica TOFD.	11
2.3	Alguns defeitos típicos em juntas soldadas.	12
3.1	Cadeia de processamento do sinal para sistemas de decisão.	14
3.2	Decomposição empírica em modos aplicada a um sinal (1).	19
3.3	Scree plot da Variância explicada <i>versus</i> número de componentes principais.	29
3.4	Diagrama de Pareto da Variância explicada <i>versus</i> número de componentes principais.	30
3.5	Arquitetura de uma rede neural do tipo MLP.	31
3.6	Matriz de confusão para um classificador binário defeito/sem-defeito.	36
3.7	Exemplo de uma curva Característica de Operação do Receptor (COR) para um classificador de três classes.	38
4.1	Cadeia de processamento de sinais sugerida.	39
4.2	Ilustração do arranjo experimental usado para obtenção dos dados.	41
4.3	Corpo de prova usado nos ensaios.	42
4.4	Formas de onda típicas para as diversas condições de interesse.	42
4.5	Fluxo de pré-processamento dos dados.	44
4.6	Organização dos dados para classificação após PCA.	44
4.7	Arquitetura da rede neural do tipo MLP utilizada neste trabalho.	45
4.8	Parâmetros de desempenho calculados para cada rodada de treinamento e seus valores médios.	46
5.1	IMFs obtidas através do algoritmo EMD considerando uma realização típica de cada condição de interesse.	48
5.2	IMFs obtidas através do algoritmo EEMD para $w_n = 0, 2$ e $N_{ens} = 10, 50$ e 100, considerando uma realização típica de cada condição de interesse.	49
5.3	IMFs obtidas através do algoritmo EEMD para $N_{ens} = 50$ e $w_n = 0, 1, 0, 2$ e 0, 4, considerando uma realização típica de cada condição de interesse.	50
5.4	IMFs obtidas através do algoritmo CEEMDAN para $w_n = 0, 2$ e $N_{ens} = 10, 50$ e 100, considerando uma realização típica de cada condição de interesse.	51
5.5	IMFs obtidas através do algoritmo CEEMDAN para $N_{ens} = 50$ e $w_n = 0, 1, 0, 2$ e 0, 4, considerando uma realização típica de cada condição de interesse.	52
5.6	IMFs obtidas a partir de uma realização típica utilizando EMD, EEMD e CEEMDAN.	53
5.7	Sobreposição dos espectros de Hilbert de todas as IMFs para a condição sem defeito (a) e para as condições com defeito (b-e), quando tais IMFs foram geradas a partir do EMD.	56
5.8	Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método EEMD com três diferentes valores de N_{ens} e $w_n = 0, 2$.	57

5.9	Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método EEMD com três diferentes valores de w_n e $N_{ens} = 50$.	58
5.10	Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método CEEMDAN com três diferentes valores de N_{ens} e $w_n = 0, 2$.	59
5.11	Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método CEEMDAN com três diferentes valores de w_n e $N_{ens} = 50$.	60
5.12	Diagrama de Pareto da variância explicada <i>versus</i> número de componentes principais para os atributos de energia, ressaltando que as linhas representam a variância explicada acumulada.	62
5.13	Produto das eficiências, PE , <i>versus</i> número de neurônios na camada oculta, N_h , para os melhores resultados (a) sem PCA e (b) com PCA, para diversas decomposições investigadas neste trabalho.	64
5.14	Produto das eficiências <i>versus</i> número de neurônios na camada oculta, considerando o algoritmo EEMD com e sem PCA para diversos valores de w_n e N_{ens} .	65
5.15	Produto das eficiências <i>versus</i> número de neurônios na camada oculta, considerando o algoritmo CEEMDAN com e sem PCA para diversos valores de w_n e N_{ens} .	66
5.16	Produto das eficiências em função dos parâmetros w_n e N_{ens} para o algoritmo EEMD sem PCA (esq.) e com PCA.	67
5.17	Produto das eficiências em função dos parâmetros w_n e N_{ens} para o algoritmo CEEMDAN sem PCA (esq.) e com PCA.	68
5.18	Variação da acurácia por classe, considerando todos os cinco <i>folds</i> com e sem PCA.	70
5.19	Curva ROC de teste para os três métodos de decomposição sem PCA (esq.) e com PCA, considerando os melhores resultados.	72

LISTA DE TABELAS

5.1	Tempo médio, em segundos, de execução dos algoritmos para obtenção das IMFs de uma única realização, considerando para os algoritmos EEMD e CEEMDAN.	55
5.2	Parâmetros do modelo classificador.	63
5.3	Comparação usando as acurácias médias de cada condição e o produto de eficiências para diversos métodos de extração de características.	68
5.4	Avaliação da classificação com base nos parâmetros de acurácia, sensibilidade, especificidade e f1-score, considerando dados de teste.	69
5.5	Matrizes de confusão para a rede neural utilizada considerando os diversos defeitos e os três diferentes métodos de obtenção das IMFs EMD, EEMD e CEEMDAN.	71
5.6	Comparação usando acurácias por cada condição de interesse e o produto de eficiências para diversos métodos de extração de características reportados na literatura e investigados nesse trabalho. Em negrito os valores obtidos neste trabalho.	74

LISTA DE ABREVIATURAS E SÍMBOLOS

Abreviaturas

BP	<i>Back propagation</i> (algoritmo)
CEEMD	<i>Complete Ensemble Empirical Mode Decomposition</i>
CEEMDAN	<i>Complete Ensemble Empirical Mode Decomposition with Adaptative Noise</i>
CGL	<i>Conjugate Gradient Algorithm with Line Search</i> (algoritmo)
COR	Característica de Operação do Receptor
DFT	<i>Discrete Fourier Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
EEMD	<i>Ensemble Empirical Mode Decomposition</i>
EMD	<i>Empirical Mode Decomposition</i>
END	Ensaaios não destrutivos
FF	Falta de fusão
FPTC	Falta de penetração/trinca
HHT	Hilbert-Huang Transform
HSA	<i>Hilbert Spectrum Analysis</i>
IC	Inclusão de escória
IMF	<i>Intrinsic Mode Function</i>
LM	<i>Levenberg-Marquardt</i> (algoritmo)
MIG	<i>Metal Inert Gas</i>
MLP	<i>Multilayer Perceptron</i>
MM	Mixagem de Modos ou <i>Mode Mixing</i>
NDE	<i>Non-Destructive Evaluation</i> ou <i>Non-Destructive Examination</i>
NDI	<i>Non-Destructive Inspection</i>
NDT	<i>Non-Destructive Testing</i>
PCA	<i>Principal Component Analysis</i>

PE	Produto das eficiências
PO	Porosidade
RNA	Rede neural artificial
ROC	<i>Receiver Operating Characteristics</i>
SD	Sem defeito
TH	Transformada de Hilbert
THH	Transformada de Hilbert-Huang
TIG	<i>Tungsten Inert Gas</i>
TOFD	<i>Time-of-flight diffraction</i>

Símbolos

$\bar{x}$	Valor da média amostral de x
ϵ	Erro sistemático aleatório ou amplitude do ruído gaussiano branco ou tensor deformação
ϵ_n	Desvio padrão final do erro
$\hat{x}$	Valor estimado ou previsto de x
$\mathbf{X}^T$	Matriz transposta de X
$\mathbf{X}_{m \times n}$	Matriz X com m linhas e n colunas
$\mathcal{F}$	Transformada de Fourier
$\mathcal{H}$	Transformada de Hilbert
$\overline{IMF}_n$	n -ésima IMF complementar
$\Re(z)$	Parte real de um número complexo z
σ	Tensor tensão
b_i	Polarização (em inglês, <i>bias</i>)
c	Tensor elasticidade
$COV[A(t)]$	Covariância de um processo aleatório $A(t)$
$E[A(t)]$	Esperança de uma processo aleatório aleatório $A(t)$
$h(\cdot)$	Função de ativação de um neurônio
$h(\omega)$	Espectro marginal de Hilbert
IMF_n	n -ésima IMF

N_{ens}	Número de <i>ensembles</i>
N_h	Número de neurônios na camada oculta
P	Valor principal de Cauchy da integral singular
p_X	Função densidade de probabilidade da variável aleatória X
$Var[A(t)]$	Variância de um processo aleatório $A(t)$
w_i	Peso sináptico
w_n	Amplitude do ruído gaussiano branco

CONTEÚDO

Capítulo 1—Introdução	1
1.1 Motivação	3
1.2 Objetivos	3
1.2.1 Objetivos específicos	4
1.3 Estrutura do documento	4
Capítulo 2—Fundamentos dos Ensaios Não Destrutivos com Ultrassom	6
2.1 Classificação dos ensaios não destrutivos	7
2.2 Ensaios não destrutivos baseados em ultrassom	8
2.2.1 Tempo de voo da onda difratada (TOFD)	9
2.3 Descontinuidades e defeitos em juntas soldadas por fusão	11
2.4 Não linearidade em materiais metálicos	12
Capítulo 3—Processamento de Sinais aplicado a sinais de ultrassom	14
3.1 Transformada de Hilbert-Huang (THH)	17
3.1.1 Decomposição Empírica em Modos (EMD)	17
3.1.1.1 Funções de Modo Intrínseco (IMF)	18
3.1.1.2 Mixagem de Modos	21
3.1.2 Decomposição Empírica em Modos Conjuntos (EEMD)	22
3.1.3 Decomposição Empírica em Modos Conjuntos Completos (CEEMD)	23
3.1.4 Decomposição Empírica em Modos Conjuntos Completos com Ruído Adaptativo (CEEMDAN)	24
3.1.5 Análise espectral em espaços de Hilbert	24
3.2 Trabalhos relacionados	26
3.3 Classificação de séries temporais	28
3.3.1 Análise de Componentes Principais (PCA)	28
3.3.2 Redes Neurais Artificiais (RNA)	30
3.3.2.1 Perceptron multicamadas (MLP)	31
3.3.3 Dilema viés-variância	32
3.3.4 Validação Cruzada	33
3.3.4.1 Método <i>leave-one-out</i>	34
3.3.4.2 Método <i>k-Fold</i>	34
3.3.5 Avaliação do modelo	35
Capítulo 4—Metodologia	39
4.1 Procedimento experimental	40
4.2 Parâmetros de avaliação do modelo	45
Capítulo 5—Resultados e Discussão	47

5.1 Obtenção das funções de modo intrínseco	47
5.2 Aplicação da transformada de Hilbert	55
5.3 Análise de componentes principais	61
5.4 Classificação dos defeitos utilizando MLP-RNA	62
5.5 Análise comparativa com trabalhos relacionados	73
Capítulo 6—Considerações finais	75
6.1 Sugestões de trabalhos futuros	77
Apêndice A—Publicações	85
A.1 XIV Congresso Brasileiro de Inteligência Computacional (CBIC 2019) . . .	85
Anexo A—Implementação dos métodos EMD, EEMD e CEEMDAN	86
A.1 Algoritmo EMD	86
A.2 Algoritmo EEMD	98
A.3 Algoritmo CEEMDAN	99

INTRODUÇÃO

A combinação de materiais para obtenção de estruturas com características específicas tem recebido atenção de engenheiros e cientistas ao longo dos anos (2). Materiais compósitos, como assim são chamados, tornaram-se os principais componentes na fabricação de aeronaves e veículos espaciais, uma vez que são resistentes e leves (3). Aliados a estes materiais, os processos de manufatura desempenham um papel fundamental na construção de estruturas robustas e confiáveis, permitindo o aproveitamento adequado das características dos materiais compósitos.

Devido ao nível de criticidade das aplicações supracitadas, o diagnóstico de possíveis falhas em estruturas concebidas a partir de tais materiais e que possam ter origem no processo de manufatura se torna algo imprescindível para assegurar o bom funcionamento dos equipamentos e sistemas onde são aplicados. Outrossim, é preciso garantir a segurança dos operadores e demais indivíduos que, direta ou indiretamente, lidem com tais estruturas, minimizando assim os riscos de acidentes, desperdício de recursos ou danificação de ativos.

Ao longo dos anos, diversos métodos e técnicas foram criados e aperfeiçoados para permitir o diagnóstico eficaz de falhas em estruturas mecânicas para várias aplicações, envolvendo, por exemplo, a verificação de descontinuidades em soldas metálicas, fraturas em tanques de armazenamento ou ainda inspeção de ferramentas na indústria automobilística (4-7).

Nesse sentido, os ensaios não destrutivos (END), assim chamados pois não danificam ou alteram as características da estrutura ou material sob teste, têm apresentado uma série de importantes ferramentas no controle de qualidade dos processos e na garantia da confiabilidade dos produtos. Dentre as múltiplas técnicas existentes de END, destacam-se àquelas que utilizam ultrassom, pois apresentam baixo custo (8,9) quando comparado com outros métodos e, em geral, possuem ótima precisão, eficiência e confiabilidade nos resultados. Além disso, não apresentam riscos ao operador quando comparado, por exemplo, aos ensaios baseados em raio-x, e sua execução é simples. Convém ainda

salientar que a análise dos resultados do ensaio é feita pelo operador que deve estar devidamente treinado e/ou possuir significativa experiência ([10, 11]), o que mesmo assim não o exime de possíveis erros de interpretação, sendo, portanto, um fator limitante que deve ser considerado ante a aplicação da técnica.

Os dados obtidos através dos ensaios podem ser processados digitalmente de modo a fornecer informações relevantes para auxiliar a tomada de decisão, ou ainda no treinamento de máquinas de aprendizado (do inglês, *machine learning*), capazes de realizar a classificação automática de um defeito, por exemplo.

Alguns trabalhos ([12, 13]) têm aplicado diversas técnicas de pré-processamento em sinais obtidos através de END baseados em ultrassom com o propósito de treinar uma rede neural artificial (RNA) para a classificação automática de descontinuidades em cordões de solda.

Os resultados apresentados pela classificação utilizando uma RNA em ([12, 13]) têm exibido variações de acordo às diferentes técnicas de pré-processamento e de extração de características, sendo a transformada discreta de Fourier (em inglês, *Discrete Fourier Transform*, DFT) a que mostrou melhor resultado, apresentando 94,8% de acurácia, o que nos fornece indícios sobre a necessidade de investigação de novas abordagens ou ainda a combinação delas, buscando não somente melhorar a acurácia na classificação, mas também possibilitar e alavancar o desenvolvimento de sistemas embarcados capazes de realizar diagnósticos automatizados, otimizando assim recursos e aumentando a confiabilidade dos sistemas. Vale ainda ressaltar que, por se tratar de um problema onde é difícil a obtenção de uma grande base de dados (problemas conhecidos como *small data*), a aplicação de algoritmos de aprendizado profundo (em inglês, *deep learning*), torna-se limitada, uma vez que tais algoritmos necessitam de uma grande quantidade de dados (comumente chamado de problemas de *big data*).

Nesse contexto, este trabalho propõe investigar a utilização da Transformada de Hilbert-Huang (THH, ou, em inglês, *Hilbert-Huang Transform*, HHT) como uma possível técnica de pré-processamento e extração de características, uma vez que se mostra adequada para o uso em sinais não-lineares e não-estacionários ([1, 14]) pois, devido à sua capacidade adaptativa, representações potencialmente mais próximas das classes de interesse podem ser obtidas, o que a difere das técnicas utilizadas nos trabalhos supramencionados.

1.1 Motivação

Aplicações em que requisitos de alta confiabilidade e qualidade devem ser cumpridos, demandam uma avaliação criteriosa da integridade dos materiais e das estruturas a partir deles construídas. Nesse sentido, os ensaios não destrutivos possibilitam o auxílio no diagnóstico de descontinuidades oriundas dos processos de manufatura.

Atualmente existem equipamentos que permitem a visualização em tempo real da estrutura através de imageamento acústico, mas a interpretação da informação fica a critério do operador, o que não elimina a possibilidade de uma compreensão equivocada e, portanto, o sucesso da análise fica atrelado à experiência do operador.

A concepção e utilização de um sistema inteligente capaz de fornecer o diagnóstico automatizado, minimizando possíveis erros de diagnóstico, reduzindo a dependência do caráter subjetivo de avaliação do operador e fornecendo um sólida base para a tomada de decisão, torna-se uma importante alternativa. É imprescindível, no entanto, o exame adequado das técnicas de processamento de sinais, levando em consideração a dinâmica do fenômeno físico em análise.

Em (15), os autores mostram a natureza não-linear das ondas acústicas quando estas interagem com certas descontinuidades, sendo portanto, importante a utilização de uma ferramenta que seja capaz de lidar com não-linearidades. Surge, neste âmbito, a transformada de Hilbert-Huang que, por criar uma base de projeção a partir dos próprios sinais a serem decompostos, mostra-se como uma ferramenta adequada na análise de sinais não-lineares e/ou não-estacionários.

1.2 Objetivos

O principal objetivo deste trabalho é o de avaliar o desempenho da transformada de Hilbert-Huang como uma ferramenta para extração de características em sinais de ultrassom que foram obtidos a partir da técnica TOFD (*Time-Of-Flight Diffraction*) para diversas condições de defeito em chapas soldadas, levando-se em consideração as principais vantagens e desvantagens desta ferramenta.

1.2.1 Objetivos específicos

- estudar a transformada de Hilbert-Huang como uma ferramenta alternativa às transformadas usualmente utilizadas (DFT, DCT, DWT, dentre outras), uma vez que aquela, como ferramenta adaptativa, torna-se apropriada ao tratamento de dados não-lineares e não-estacionários;
- estudar e avaliar a influência de alguns parâmetros dos métodos EEMD e CEEMDAN na extração de características de sinais de ultrassom, encontrando os valores adequados à aplicação proposta;
- compreender e relacionar os fenômenos físicos com as funções de modo intrínseco obtidas por meio da aplicação do algoritmo de decomposição empírica em modos (EMD e seus variantes);
- projetar e utilizar um modelo estatístico baseado em rede neural para avaliar a capacidade da THH em gerar atributos das classes de interesse.

1.3 Estrutura do documento

A organização deste documento é a que segue: no Capítulo 2 são apresentados os fundamentos dos ensaios não destrutivos com foco nos ensaios que se baseiam em ultrassom, particularmente no método baseado no *tempo de voo da onda difratada* (do inglês, *time-of-flight diffraction*, TOFD), enquanto o Capítulo 3 traz uma extensa descrição da decomposição empírica em modos (do inglês, *empirical mode decomposition*, EMD) e suas variantes: *decomposição empírica em modos conjuntos* (do inglês, *ensemble empirical mode decomposition*, EEMD) e *decomposição empírica em modos conjuntos completos com ruído adaptativo* (do inglês, *complete ensemble empirical mode decomposition with adaptive noise*, CEEMDAN) que, em combinação com a análise espectral em espaços de Hilbert, culmina na denominada transformada de Hilbert-Huang. Ainda neste capítulo, os princípios e fundamentos das redes neurais artificiais – o que abrange também o método de validação cruzada que, como um método de reamostragem de dados, permite uma melhor avaliação do modelo da taxa de erro em dados de testes. No Capítulo 4 a metodologia do trabalho é apresentada, o que inclui uma descrição do procedimento

experimental e o detalhamento do processamento de sinais realizado e os parâmetros de avaliação do modelo de classificação. Por fim, os resultados são apresentados no [5](#) acompanhados das discussões acerca daqueles, seguida das considerações finais no Capítulo [6](#).

FUNDAMENTOS DOS ENSAIOS NÃO DESTRUTIVOS COM ULTRASSOM

Ensaio não destrutivo (END) (em inglês, *non-destructive testing*, NDT), também conhecido como *inspeção não destrutiva* (em inglês, *non-destructive inspection*, NDI), ou ainda *avaliação não destrutiva* (em inglês, *non-destructive examination*, NDE) compreende uma ampla variedade de ensaios que objetivam a inspeção e análise de componentes, elementos ou máquinas sem que as propriedades destes sejam alteradas ou que a operação sofra impactos de alguma maneira. Segundo (16), END pode ser definido como:

Nondestructive testing (NDT) is the development and application of technical methods [...] to examine materials or components in ways that do not impair the future usefulness and serviceability in order to detect, locate, measure and evaluate discontinuities, defects, and other imperfections; to assess integrity, properties and composition; and to measure geometrical characters.

Os ENDs apresentam uma série de vantagens (17), a saber:

- redução de riscos, uma vez que é possível identificar de maneira antecipada eventuais problemas nos processos metalúrgicos e de manufatura;
- redução de custos, pois reduz o tempo de manufatura, bem como níveis de rejeitos;
- melhoria da qualidade e aumento da confiabilidade, pois fornece suporte à manutenção preventiva, diminui a quantidade de paradas desnecessárias e permite melhoria contínua no projeto de peças e equipamentos;
- permite a manutenção de um programa de qualidade e por conseguinte favorece a reputação das companhias, aumento de vendas, dentre outros.

Por outro lado, a utilização de ensaios não destrutivos pode estar condicionada ao treinamento e capacitação adequados para os técnicos e operadores, pois podem ser necessárias habilidades específicas para aplicação e interpretação dos resultados a depender do método utilizado.

2.1 Classificação dos ensaios não destrutivos

Os métodos utilizados nos ENDs podem ser agrupados de acordo com o princípio físico utilizado no ensaio do material ou estrutura. Os métodos mais comuns em ENDs são:

- **inspeção visual (VT):** usualmente o primeiro método a ser considerado, antes de qualquer outro método mais sofisticado. Neste método, a detecção de descontinuidades, falhas e anomalias é feita utilizando apenas o contato visual a olho nu ou com auxílio de lentes amplificadoras, funcionando apenas em descontinuidades superficiais. Câmeras e filmadoras também podem ser utilizadas para inspeção visual à distância.
- **líquidos penetrantes (LT):** método utilizado para detecção de descontinuidades abertas em superfície. Nele, um líquido penetrante é aplicado na superfície do material a ser inspecionado. Após remoção do excesso de líquido e secagem da superfície, utiliza-se um material revelador que absorve o líquido que permaneceu na descontinuidade e mostra a existência, localização, tamanho e natureza da descontinuidade.
- **partículas magnéticas (MT):** neste método, utilizado em materiais ferromagnéticos, a estrutura a ser inspecionada deve ser magnetizada, e em seguida deposita-se sob a região a ser inspecionada um líquido ou pó composto de partículas magnetizáveis, capazes de se alinharem a um campo magnético. O padrão exibido pelas partículas quando submetidas ao campo da estrutura em análise pode indicar descontinuidades.
- **correntes parasitas (ET):** neste ensaio, uma bobina excitada por uma corrente alternada é colocada em proximidade com o material metálico a ser inspecionado. O campo induzido no material sob teste cria uma corrente elétrica conhecida como correntes de Eddy, que por sua vez também gerará um campo eletromagnético. A interação entre os campos devido à indutância mútua sofre influência da espessura do material inspecionado, bem como de eventuais descontinuidades presentes na estrutura, e seus efeitos podem ser percebidos na bobina excitadora.
- **radiografia (RT):** envolve a utilização de uma fonte radioativa, que emite raios X ou γ no material sob inspeção. Uma chapa reveladora é posicionada do lado oposto

ao lado de incidência da radiação, e eventuais descontinuidades poderão ser vistas a partir dela, uma vez que a radiação será absorvida de maneira diferente nessas condições.

- **ultrassom (UT):** neste tipo de teste, uma onda mecânica de alta frequência é gerada na estrutura. A interação das ondas com o material permite não só a sua caracterização, mas também a identificação e localização de descontinuidades.

2.2 Ensaios não destrutivos baseados em ultrassom

Os END com base em ultrassom podem ser divididos basicamente em duas categorias: àqueles que utilizam ondas de cisalhamento (em inglês, *shear waves*), também conhecido como *angle beam inspection*, e que permitem a inspeção na superfície do material e também em seu interior; e os que utilizam ondas de compressão (em inglês, *compression waves*) que permitem apenas a inspeção interna do material, bem como a estimativa de sua espessura [18]. Na primeira categoria, emprega-se usualmente um transdutor inclinado num ângulo fixo (45°, 60° ou 70°), o que possibilita a propagação de ondas laterais e consequentemente a detecção de trincas e inclusões próximas à superfície. Por outro lado, nos ensaios com base em ondas de compressão, o transdutor é posicionado perpendicularmente à região a ser inspecionada, de modo que a incidência da onda ultrassônica será normal à superfície, sendo, portanto, primariamente voltado para inspeções internas no material [19,20]. Dentro dessas categorias, são três os métodos de ensaio mais comuns:

- 1) **pulso-eco** (em inglês, *pulse-echo*): onde um transdutor de dois elementos (transmissor e receptor) é posicionado perpendicularmente à superfície do material a ser inspecionado e então um pulso acústico é emitido. As reflexões (ecos) permitem a avaliação de descontinuidades, bem como da espessura do material.
- 2) **matriz faseada** (em inglês, *phased array*, PA): neste tipo de ensaio, um conjunto de transdutores (transmissores e receptores) são utilizados e podem ser controlados de maneira independente, o que permite a focalização da onda ultrassônica e possibilita a avaliação da estrutura em diversas regiões, sem a necessidade de deslocamento da sonda.
- 3) **tempo de voo da onda difratada** (em inglês, *time-of-flight diffraction*, TOFD):

utiliza dois transdutores, um para recepção e outro para emissão da onda acústica, que permitem a avaliação do material/estrutura a partir da difração causada pelas descontinuidades e será detalhado na seção a seguir.

Além da inspeção do material, os END baseados em ultrassom permitem ainda a medição da espessura de chapas e diâmetro de barras, apresentando uma série de vantagens quando comparados com outros métodos de inspeção não destrutiva, tais como:

- teste rápido com boa resolução e sensibilidade;
- usualmente apenas a superfície a ser examinada necessita estar acessível;
- é possível estimar tamanho, orientação forma e natureza dos defeitos;
- operação segura, sem impacto em equipamentos ou materiais nas proximidades;
- portabilidade, posto que equipamentos portáteis estão disponíveis comercialmente.

Por outro lado, as principais desvantagens são:


- procedimento deve ser realizado com cautela e necessidade de um técnico experiente;
- conhecimento técnico é indispensável para um procedimento de inspeção correto;
- descontinuidades próximas às superfícies podem não ser detectadas;
- requer a utilização de materiais para acoplamento entre transdutor e estrutura a ser inspecionada;
- necessita de padrões de referência para calibração e caracterização das descontinuidades.

2.2.1 Tempo de voo da onda difratada (TOFD)

No método baseado no tempo de voo da onda difratada (em inglês, *Time-of-Flight Diffraction*, TOFD) uma onda mecânica de alta frequência (usualmente entre 1 a 50 MHz) é introduzida no material sob teste por meio de um transdutor eletromecânico que converte sinais elétricos em vibrações mecânicas. Tais transdutores são comumente chamados de sondas. A onda emitida interage com o material sofrendo reflexões e difrações que são

coletadas pelo mesmo transdutor ou ainda por outro transdutor. No caso da técnica TOFD (do inglês, *Time Of Flight Diffraction*), o tempo de retorno da onda permite detectar falhas no material, além disso, os diferentes tipos de falhas produzem sinais com características distintas, o que permite ainda identificar o tipo de falha. A Figura 2.1 mostra como as ondas se comportam no material ao utilizar-se a técnica TOFD.

Figura 2.1. Ilustração da técnica TOFD.



Fonte: Elaborada pelo autor.

A onda inserida no material sofrerá reflexão no fundo do material inspecionado, o que produz o chamado eco de fundo, além de uma onda lateral. As descontinuidades e falhas no material também produzirão difrações que podem ser captadas pela sonda receptora com auxílio de um osciloscópio ou equipamento específico. A Figura 2.2 mostra um equipamento disponível comercialmente que permite realizar o procedimento usando a técnica TOFD. Este equipamento é, em geral, composto por duas sondas: uma para emissão e uma para recepção das ondas (embora haja a possibilidade de se utilizar a mesma sonda para emissão e recepção do sinal), e um dispositivo que permite o registro e armazenamento dos sinais medidos. Aparelhos mais modernos permitem a visualização em tempo real da estrutura desses materiais por meio de imagens bidimensionais.

Figura 2.2. Equipamento que permite a aplicação da técnica TOFD.



Fonte: Página da Olympus¹.

2.3 Descontinuidades e defeitos em juntas soldadas por fusão

Descontinuidades nos processos de soldas podem ter causas variadas, em geral relacionadas com o processo de soldagem, o projeto mecânico ou o comportamento metalúrgico² (21). O processo de soldagem e o projeto mecânico podem afetar as tensões na solda ou na *zona afetada pelo calor* (ZAC) – também chamada de *zona termicamente afetada* (ZTA), ao passo que as descontinuidades metalúrgicas podem influenciar na distribuição de tensões e causar alterações das propriedades mecânicas e químicas da região soldada ou da ZAC.

As descontinuidades podem amplificar as tensões devido a uma redução na área de seção transversal. Essas descontinuidades podem ser vistas a partir das seguintes características:

- 1) tamanho;
- 2) forma;
- 3) orientação com respeito ao eixo de tensão principal;
- 4) localização da descontinuidade em relação à solda, às superfícies da junta soldada e às seções críticas da estrutura.


¹Disponível em <<https://www.olympus-ims.com/pt/weld-solutions/tofd-solutions/>>. Acesso em 20 ago. 2020.

²Entende-se por comportamento metalúrgico o comportamento que um metal apresenta ao ser submetido aos diversos processos metalúrgicos, tais como fundição, laminação, trefilação, dentre outros.

As imperfeições e descontinuidades quando acima de um critério de aceitação, tornam-se defeitos (22). Neste trabalho, os termos serão utilizados de maneira indistinta, visto que uma aplicação normativa não se faz necessária para que os objetivos do trabalho sejam atingidos. Alguns dos principais defeitos, que são considerados neste trabalho são:

- **Trinca:** imperfeições oriundas de uma ruptura local no material, que pode surgir como consequência do resfriamento ou tensões.
- **Porosidade:** presença de cavidades na solda causadas pelo aprisionamento de gás durante o processo de soldagem.
- **Inclusões de escória:** partículas que ficam aprisionadas no metal solidificado.
- **Falta de fusão:** trata-se da ausência de coalescimento de parte do cordão de solda.

A Figura 2.3 mostra alguns defeitos típicos em juntas soldadas.



Fonte: Adaptado de (21).

2.4 Não linearidade em materiais metálicos

Segundo a lei de Hooke para meios contínuos, também conhecida como lei de Hooke generalizada, tem-se a seguinte relação:

$$\sigma = -c\epsilon, \quad (2.1)$$

onde: σ é o tensor tensão, ϵ é o tensor deformação e c é um tensor elasticidade.

Materiais em conformidade com (2.1) apresentam, portanto, uma relação linear na curva de tensão versus deformação. Alguns trabalhos (15, 23) demonstraram que estruturas dotadas de certas descontinuidades, apresentam uma relação entre tensão e deformação não-linear.

Essa característica tem sido então utilizada em diversos trabalhos (24, 25) como mecanismo de detecção de falhas em diversos materiais a partir da análise de componentes harmônicas.


Neste trabalho, a utilização da HHT também permite, ao menos a priori, o tratamento adequado à tais não-linearidades sendo, portanto, uma ferramenta candidata apropriada para extração de características.

PROCESSAMENTO DE SINAIS APLICADO A SINAIS DE ULTRASSOM

A utilização de técnicas de processamento de sinais permite, dentre diversas aplicações, a estimação de parâmetros de um sinal, filtragem de ruído e separação de sinais. Além disso, possibilita a automatização do processo de diagnóstico de discontinuidades, falhas ou anomalias e, por conseguinte, mitiga possíveis imprecisões devido a inexperiência do operador, reduzindo ainda o carácter parcial de decisão deste e aumentando consequentemente a eficácia do diagnóstico.

A Figura 3.1 mostra uma cadeia de processamento típica em problemas de decisão.

Figura 3.1. Cadeia de processamento do sinal para sistemas de decisão.



Fonte: Elaborada pelo autor.

Após a obtenção dos *dados experimentais*, realizada com auxílio de um arranjo experimental dotado de transdutores e/ou sensores, por exemplo, algumas transformações podem ser necessárias na etapa de *pré-processamento*, visando não somente o aumento da eficácia e acurácia da classificação, mas também a otimização de recursos de processamento e armazenamento. Segundo (26), a etapa de pré-processamento compreende uma série de transformações que podem ou não alterar a dimensionalidade dos dados, podendo ser agrupadas em:

- *Uniformização*: visa uniformizar a representação da informação em objetos que são comparáveis fisicamente. Desse modo, operações aritméticas como adição e sub-

tração podem ser realizadas diretamente, sem necessidade de conversões adicionais. Um dos métodos mais comuns de uniformização envolvem a centralização dos dados em torno da média e a mudança de escala, operações que podem ser sintetizadas a partir da expressão: $x'_i = (x_i - \mu_i)/\sigma_i$, onde μ_i e σ_i representam a média e o desvio padrão de x_i , respectivamente.

- *Normalização*: visa tornar a representação da informação independente de outros fatores, como por exemplo no caso de uma imagem, cujo pixel pode depender do tamanho da projeção em um determinado dispositivo.
- *Aprimoramento do sinal*: objetiva melhorar a relação sinal ruído (SNR) através da aplicação de filtros para eliminação de ruídos, suavização, nitidez etc. Métodos comuns envolvem a aplicação da transformada de Fourier, wavelets, etc.
- *Extração de características locais*: utilizada em dados estruturados (sequencial ou espacialmente). Envolvem a aplicação de métodos de convolução derivados de maneira ad hoc e, portanto, as técnicas aplicadas neste grupo são específicas para cada problema.
- *Métodos de incorporação¹ de espaço linear e não-linear*: utilizados quando a dimensionalidade dos dados é alta, tendo como objetivo reduzi-la. Alguns exemplos incluem a Análise de Componentes Principais (em inglês, *Principal Component Analysis*, PCA).
- *Expansões não-lineares*: tem efeito oposto ao item anterior, ou seja, neste caso objetiva-se aumentar a dimensionalidade dos dados.

Após o pré-processamento, a etapa de *extração de características* pode ser aplicada. Esta etapa pode ser compreendida pelos processos de *construção de características* e *seleção de características*.

Ainda segundo (26), as principais atividades desta etapa podem ser agrupadas segundo quatro motivações, a saber:

- *redução geral de dados*: cujos objetivos estão relacionados com redução do tempo

¹tradução livre para “*embedding methods*”

computacional no processamento dos dados, além de redução nos requisitos de armazenamento;

- *redução de características*: com a finalidade de otimizar os recursos a partir da utilização de um conjunto de dados reduzido, bem como facilitar o processo de coleta de novos dados;
- *aumento de desempenho*: cujo intuito é o de aumentar a acurácia na predição ou classificação;
- *compreensão dos dados*: ou, em inglês, *data understanding*, cujo propósito é a obtenção de conhecimento acerca do conjunto de dados ou ainda facilitar a visualização e interpretação dos mesmos.

É importante salientar que alguns métodos utilizados na etapa de pré-processamento são capazes de construir *caraterísticas* ou *atributos*. Seja, por exemplo, um sinal $x(t)$ que atende às condições de Dirichlet (27). Após a transformada de Fourier, obtém-se amplitude $|X(\omega)|$ e fase $\angle X(\omega)$ que, em conjunto, compõem o chamado espectro de Fourier do sinal $x(t)$. Neste contexto, caso o espectro de Fourier, ou tão somente parte dele ($|X(\omega)|$ ou $\angle X(\omega)$) seja utilizado no processo de classificação, sugere-se oportunamente a utilização do termo *variável bruta* para $x(t)$, em contraste com as *caraterísticas* para $X(\omega)$ e $\angle X(\omega)$, uma vez que estas foram construídas a partir de $x(t)$.

Em (12,13,28), os autores descrevem as transformadas discretas de Fourier (DFT), Cosseno (DCT) e Wavelet (DWT) como ferramentas utilizadas nesta etapa. Em seguida, na etapa de seleção das características, reduz-se a dimensão dos dados utilizando técnicas como análise de componentes principais (do inglês, *Principal Component Analysis*, PCA) ou análise de componentes independentes (do inglês, *Independent Component Analysis*, ICA). Vale ressaltar que a seleção das características possui um grande impacto no processo de classificação dos dados.

Por fim, a etapa de *classificação* consiste na tentativa de solução de um *problema de classificação*, onde um modelo estatístico deve ser ajustado através de um processo de aprendizagem, supervisionado ou não supervisionado.

Apesar das técnicas previamente mencionadas terem sido utilizadas nos trabalhos supracitados apresentando resultados satisfatórios, a utilização de transformadas lineares

em dados oriundos de sistemas não-lineares e/ou não-estacionários podem ofuscar ou distorcer importantes informações dos processos físicos envolvidos [1].

Neste contexto, surge como uma ferramenta alternativa, a transformada de Hilbert-Huang, adequada para o tratamento de dados não-lineares e/ou não-estacionários, possibilitando uma interpretação mais realística dos processos físicos os quais os dados representam. A grande vantagem desta transformada é que a sua base (ou, em inglês, *kernel*) é obtida de maneira completamente empírica, permitindo uma abordagem adaptativa e portanto eliminando os problemas intrínsecos ao uso de transformadas lineares sobre dados não-lineares e/ou não-estacionários.

3.1 Transformada de Hilbert-Huang (THH)

A transformada de Hilbert-Huang (THH) (ou, em inglês, *Hilbert-Huang Transform*, HHT) combina a análise espectral em espaços de Hilbert (do inglês, *Hilbert Spectrum Analysis*, HSA), a partir da transformada de Hilbert (TH), e a decomposição empírica em modos (do inglês, *Empirical Mode Decomposition*, EMD) [1, 29], tendo o seu desenvolvimento sido motivado pela necessidade da descrição detalhada de sinais oscilatórios não-lineares e que apresentam variações estatísticas com respeito ao tempo (não-estacionaridade).

3.1.1 Decomposição Empírica em Modos (EMD)

Conforme apresentado em [14, 30], o algoritmo de decomposição empírica em modos (do inglês *Empirical Mode Decomposition*, EMD) se torna mais indicado quando o objetivo é tratar dados oriundos de processos não-lineares e não-estacionários. Em contraste com os métodos convencionais, EMD é um método intuitivo, direto e adaptativo. O método consiste na hipótese de que qualquer dado é constituído de diferentes modos elementares intrínsecos de vibração. Cada modo intrínseco, seja ele linear ou não-linear, representa uma vibração elementar, que terá iguais números de máximos e de mínimos, além de igual número de cruzamentos em zero. Além disso, a oscilação é simétrica com respeito à média local. Em qualquer instante de tempo, o sinal pode ser composto de diferentes modos de vibração superpostos. Cada um destes modos é representado por

uma função de modo intrínseco (do inglês, *Intrinsic Mode Function*, IMF).

3.1.1.1 Funções de Modo Intrínseco (IMF)


A IMF é uma função que satisfaz as seguintes condições (31):

- o número de máximos e mínimos e o número de cruzamentos em zero devem ser iguais, ou diferentes em, no máximo, 1 (uma) unidade, para um certo conjunto de dados;
- em qualquer ponto, a média das envoltórias definido pelos mínimos locais e pelos máximos locais deve ser zero.

Dada a definição anterior, a obtenção de uma IMF segue o procedimento descrito a seguir, conhecido como peneiramento (em inglês, *sifting*):

- 1) Identifica-se todos os pontos de máximo e de mínimo do sinal;
- 2) conecta-se todos os pontos de máximo por meio de uma interpolação cúbica do tipo *spline*, obtendo-se a envoltória superior. Repete-se o procedimento para os pontos de mínimo para se obter a envoltória inferior;
- 3) obtém-se a média entre as envoltórias superior e inferior, designada por $m_1(t)$;
- 4) obtém-se $h_1(t) = x(t) - m_1(t)$, onde $x(t)$ é o sinal a ser decomposto;
- 5) repete-se o procedimento até que uma condição de parada seja alcançada.

A Figura 3.2 mostra um sinal aleatório e suas envoltórias superior e inferior obtidas a partir da interpolação dos pontos de máximo e mínimo, respectivamente, bem como a média obtida entre tais envoltórias.

Figura 3.2. Decomposição empírica em modos aplicada a um sinal (1).

Fonte: Elaborada pelo autor.

O processo de peneiramento tem dois objetivos: (i) eliminar sobreposições de modos de vibração² e (ii) tornar os perfis de onda mais simétricos. O primeiro propósito deve ser alcançado para que a frequência instantânea obtida pela transformada de Hilbert tenha significado físico, aproximando-se do modo de vibração real, e o segundo para o caso em que duas oscilações vizinhas tenham amplitudes muito diferentes (1, 29). Portanto, este procedimento tem de ser repetido quantas vezes for necessário, de modo a garantir que o sinal obtido esteja de acordo com a definição de IMF.

No procedimento acima, $h_1(t)$ deve ser tratada como uma IMF primitiva, mas na próxima rodada do procedimento, $h_1(t)$ tornar-se-á o sinal a ser decomposto, como segue:

$$h_{11}(t) = h_1(t) - m_{11}(t), \quad (3.1)$$

onde:

$m_{11}(t)$ é a média das envoltórias superior e inferior obtidos a partir da interpolação dos pontos máximos e mínimos, respectivamente, de $h_1(t)$.

Generalizando,

$$h_{1k}(t) = h_{1(k-1)}(t) - m_{1k}(t). \quad (3.2)$$

²tradução livre para “*riding waves*”.

Após as repetições do procedimento, obtém-se a primeira IMF, denominada $c_1(t)$, ou seja,

$$c_1(t) = h_{1k}(t) \quad (3.3)$$

Convém salientar que o procedimento segue até que seja atingido um critério de parada, em geral definido de maneira *ad hoc*. Historicamente, dois critérios têm sido utilizados por (14, 32): o teste de convergência de Cauchy, onde o parâmetro

$$SD_k = \frac{\sum_{t=0}^T |h_{k-1}(t) - h_k(t)|^2}{\sum_{t=0}^T h_{k-1}^2(t)} \quad (3.4)$$

deve possuir valores pequenos, ou ainda o critério do número S , onde o processo de peneiramento será repetido S vezes consecutivas, até que o número de cruzamentos por zero ou o número de máximos e mínimos permaneça o mesmo ou que seja diferente no máximo em uma unidade. Ambos critérios trazem uma série de dificuldades do ponto de vista prático: o critério baseado no teste de convergência de Cauchy não está relacionado com a definição da IMF, ou seja, um parâmetro SD_k pequeno não garante que a função terá o mesmo número de cruzamentos em zero ou mesmo número de máximos/mínimos, por outro lado, a seleção do número S deve ser justificada rigorosamente (1). Em (32), os autores apresentam resultados baseados em testes empíricos para auxiliar na escolha do número S , chegando a conclusão que, para otimização do processo de peneiramento, o número S deve estar entre 4 e 8.

Assumindo que o critério de parada foi selecionado, então a primeira IMF, $c_1(t)$, pode ser encontrada. De maneira geral, $c_1(t)$ possui o componente de menor período do sinal, que pode então ser retirada do sinal original, ou seja,

$$r_1(t) = x(t) - c_1(t). \quad (3.5)$$

Como o resíduo $r_1(t)$ pode ainda conter variações de períodos maiores, tal resíduo torna-se um novo dado para uma nova rodada no processo de peneiramento, ou seja,

$$\begin{aligned} r_2(t) &= r_1(t) - c_2(t) \\ &\vdots \\ r_n(t) &= r_{n-1}(t) - c_n(t), \end{aligned} \quad (3.6)$$

até que $r_n(t)$ seja um valor constante, uma função monotônica ou ainda uma função com apenas um máximo ou mínimo, de maneira que nenhuma IMF pode ser extraída (32).

Conjunto de dados que apresentem uma média nula podem ainda possuir um resíduo diferente de zero. Caso o conjunto de dados possua uma tendência, o resíduo será tal tendência (32).

Somando as equações (3.5) e (3.6), obtém-se

$$x(t) = \sum_{j=1}^n c_j(t) + r_n(t), \quad (3.7)$$

que representa, portanto, a decomposição do dado $x(t)$ em n modos empíricos mais o resíduo $r_n(t)$, sendo este último uma constante ou uma tendência para a média.

3.1.1.2 Mixagem de Modos

O algoritmo EMD apresenta-se como uma ferramenta de decomposição eficiente, possuindo, no entanto, algumas desvantagens que devem ser consideradas ante a sua utilização. Um dos problemas mais relevantes no que tange à utilização do EMD é conhecido como *mixagem de modos* (ou, em inglês, *mode mixing*), que relaciona-se com o fato de que uma IMF pode conter componentes de outro modo de vibração, como consequência da possibilidade de, no processo de peneiramento, um modo não contribuir nitidamente com pontos de máximo e/ou mínimo. Em (33), os autores categorizam este problema em dois subgrupos, de acordo com as causas que dão lhe origem:

- 1) pela proximidade de dois componentes de frequência;
- 2) pela presença de intermitências no sinal.

Ainda segundo (33), alguns trabalhos na literatura têm apresentado soluções relativas a causa 2, deixando, no entanto, a causa 1 em segundo plano.

No sentido de contornar o problema de mixagem de modos, ao menos quando a origem do problema está relacionada com a presença de intermitências, algumas adaptações ao algoritmo EMD têm sido apresentadas ao longo dos anos. Em 2009, (34) propuse-

ram o EEMD (*Ensemble Empirical Mode Decomposition*), um método de ruído assistido que permite mitigar tal problema a partir da adição de um ruído branco gaussiano com amplitude finita ao sinal de interesse.

3.1.2 Decomposição Empírica em Modos Conjuntos (EEMD)

O algoritmo de decomposição empírica em modos conjuntos (EEMD) segue um procedimento similar ao EMD, diferenciando-se, contudo, da adição de um ruído branco gaussiano ao sinal de interesse, $x(t)$, que será decomposto. Além disso, esse procedimento deve ser repetido N_{ens} vezes, o que gera N_{ens} conjuntos (ou *ensembles*), ou seja,

$$x_i(t) = x(t) + w_i(t) \Big|_{i=1}^{N_{ens}} \quad (3.8)$$

onde: $x_i(t)$ é o sinal de interesse adicionado do ruído $w_i(t)$;

$w_i(t)$ é uma realização do processo aleatório $W(t)$, cuja função densidade de probabilidade é dada por:

$$p_W(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}}, \quad (3.9)$$

também conhecida como função densidade de probabilidade gaussiana ou ainda função densidade de probabilidade normal, em que σ é o desvio padrão e μ a média.

As IMFs finais serão obtidas a partir da média de todos os conjuntos. Matematicamente, tem-se:

$$IMF_n = \frac{1}{N_{ens}} \sum_{i=1}^{N_{ens}} EMD_n[x_i(t)], \quad (3.10)$$

onde $EMD_n[\cdot]$ representa o procedimento que permite a obtenção da n -ésima IMF de $x_i(t)$.

Convém salientar que dois importantes parâmetros são adicionados neste método: o número de conjuntos, N_{ens} , e a amplitude do ruído branco gaussiano, ϵ , a ser acrescido ao sinal de interesse. Essa relação é dada por (34)

$$\epsilon_n = \frac{\epsilon}{\sqrt{N_{ens}}}, \quad (3.11)$$

ou, alternativamente,

$$\ln \epsilon_n + \frac{\epsilon}{2} \ln N_{ens} = 0, \quad (3.12)$$

onde ϵ_n representa o desvio padrão final do erro, o qual é definido como a diferença entre o sinal de entrada e sua IMF correspondente.

3.1.3 Decomposição Empírica em Modos Conjuntos Completos (CEEMD)

Através do EEMD é possível mitigar os efeitos da mixagem de modos e ainda problemas relacionados com *aliasing* (35). No entanto, o grande número de iterações necessárias para a remoção do ruído adicionado ao sinal de interesse torna-se uma desvantagem significativa, na medida que o custo computacional se torna elevado. O algoritmo CEEMD surge como uma evolução do EEMD, onde o processo de adição do ruído ao sinal de interesse é feito com a utilização de um par de realizações de ruído branco gaussiano de mesma amplitude porém defasados em 180°. Desta maneira, temos para o sinal de interesse $x(t)$ e o ruído gaussiano $w_i(t)$:

$$\begin{aligned} x_i(t) &= x(t) + w_i(t), \\ \bar{x}_i(t) &= x(t) - w_i(t), \end{aligned} \quad (3.13)$$

onde i é o número de conjuntos (*ensembles*) e varia entre 1 e N_{ens} de maneira semelhante ao EEMD. Desta maneira, obtém-se IMFs complementares:

$$\begin{aligned} IMF_n &= \sum_{i=1}^{N_{ens}} EMD_n[x_i(t)], \\ \overline{IMF}_n &= \sum_{i=1}^{N_{ens}} EMD_n[\bar{x}_i(t)], \end{aligned} \quad (3.14)$$

e as IMFs finais serão obtidas a partir de:

$$IMF'_n = \frac{IMF_n + \overline{IMF}_n}{2}. \quad (3.15)$$

3.1.4 Decomposição Empírica em Modos Conjuntos Completos com Ruído Adaptativo (CEEMDAN)

Uma melhoria do CEEMD foi apresentada em 2011 por [36], sendo denominada de decomposição dos modos empíricos do conjunto completo com ruído adaptativo (em inglês, *Complete Ensemble Empirical Mode Decomposition with Adaptive Noise*). Os autores reivindicam que o método permite uma reconstrução do sinal original com erro desprezível, bem como possibilita uma melhor separação espectral das IMFs com um menor custo computacional [36, 37]. Para o algoritmo EEMD, os resíduos são calculados segundo a Eq. (3.6). De maneira diferente, o algoritmo proposto por [36], propõe que apenas o primeiro resíduo seja obtido, assim:

$$r_1(t) = x(t) - \tilde{c}_1(t), \quad (3.16)$$

onde $\tilde{c}_1(t)$ é obtido da mesma maneira que para o algoritmo EEMD, possuindo aqui uma notação diferente para enfatizar a associação com o método CEEMDAN. Em seguida, aplicando-se o algoritmo EMD sobre diversas realizações de $r_1(t)$ com ruídos gaussianos adicionados, é possível obter $\tilde{c}_2(t)$ a partir da média de tais realizações. O próximo resíduo, $r_2(t)$, será então $r_2(t) = r_1(t) - \tilde{c}_2(t)$. O procedimento continua até que uma condição de parada seja alcançada.

3.1.5 Análise espectral em espaços de Hilbert

Uma vez que as funções de modo intrínseco foram obtidas, pode-se aplicar a transformada de Hilbert em cada IMF para que a frequência e energia instantâneas de cada modo de vibração sejam encontradas.

A transformada de Hilbert para uma função real $x(t)$ é definida como: [1]

$$y(t) = \mathcal{H}\{x(t)\} = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau, \quad (3.17)$$

onde P representa o valor principal de Cauchy da integral singular [1].

Assim, é possível definir uma função analítica³ $z(t)$, tal que $z(t) = x(t) + iy(t)$ ou, na forma polar, $z(t) = a(t)e^{i\theta(t)}$, onde

$$a(t) = \sqrt{x^2(t) + y^2(t)}, \quad \theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right). \quad (3.18)$$

Sendo $a(t)$ e $\theta(t)$ a amplitude e a fase instantâneas, respectivamente. Assim, obtém-se a frequência instantânea $\omega(t)$:

$$\omega(t) = \frac{d\theta(t)}{dt}. \quad (3.19)$$

O sinal original pode então ser escrito como:

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j(t) \exp \left[i \int \omega_j(t) dt, \right] \right\}, \quad (3.20)$$

onde o resíduo, r_n , foi omitido intencionalmente, uma vez que é uma função monotônica ou uma constante. Vale ressaltar ainda que a transformada de Hilbert pode tratar o resíduo como uma oscilação de período muito longo. Na prática, a consideração de excluir ou manter esta componente deve ser avaliada para evitar superestimação da energia contida no sinal.

Por outro lado, a representação do sinal em uma expansão de Fourier é dada por:

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j e^{i\omega_j t} \right\}, \quad (3.21)$$

onde: a_j e ω_j são constantes.

Comparando-se (3.20) e (3.21), pode-se compreender que as IMFs representam uma generalização da expansão de Fourier ([1, 14, 29]), em que a amplitude variável e a frequência instantânea não somente favorecem a uma expansão mais eficiente, como também permite a representação de dados não-lineares e não-estacionários.

A distribuição das amplitudes com respeito a frequência é conhecida como espectro de Hilbert, $H(\omega, t)$, e a amplitude elevada ao quadrado representa a energia espectral.

³Uma função f é analítica no ponto z_0 se f é derivável em z_0 e se existe uma vizinhança V de z_0 tal que f é derivável em todo ponto de V .

É possível definir ainda o espectro marginal, $h(\omega)$:

$$h(\omega) = \int_0^T H(\omega, t) dt, \quad (3.22)$$

útil para determinação da amplitude total (ou energia) para cada valor de frequência, uma vez que este espectro representa, do ponto de vista probabilístico, a amplitude acumulada sobre a faixa de dados considerada.

Empiricamente, diversos trabalhos tem mostrado a HHT como uma ferramenta superior de análise para dados não-lineares e não-estacionários, principalmente por ter uma base adaptativa, obtida a partir dos próprios dados (29).

3.2 Trabalhos relacionados

Diversos trabalhos na literatura têm utilizado a THH com ou sem suporte de outras técnicas de pré-processamento para resolução de problemas de classificação onde uma ou mais condições de interesse são investigadas. Em (38), os autores aplicaram a THH para predição de crises epiléticas através da utilização de sinais de eletroencefalograma (EEG), exame que permite avaliar a atividade cerebral do indivíduo, atingindo uma sensibilidade de 93,1%. Em 2015, (39) apresentaram uma implementação em FPGA (*field programmable gate array*) da transformada de Hilbert-Huang para predição de tais crises epiléticas, implementação também vista em trabalho mais recente (40).

Em 2014, (41) apresentaram uma abordagem baseada na aplicação da THH em combinação com a técnica *vizinho falso mais próximo* (em inglês, *false nearest neighbors*, FNN) e redes neurais artificiais para modelagem e predição de eletrocardiogramas (ECG), com resultados promissores: raiz do erro quadrático médio (em inglês, *root mean squared error*, RMSE) iguais a 0,031, 0,05 e 0,085 para horizontes de predição de 0,0028, 0,0056 e 0,0083 segundos, respectivamente.

Mais recentemente, (42) apresentaram em seu trabalho classificação de imagens hiper-espectrais com base na THH, obtendo 100% de acurácia, embora pontuando a necessidade de uma investigação mais aprofundada acerca da composição efetiva dos modos que compõem a imagem para os diferentes tipos de imagem e regiões de interesse.

Num contexto diferente, (43) os autores utilizaram máquinas de vetores de suporte (em inglês, *support vector machines*, SVM) para avaliar os efeitos de borda (em inglês, *end effects*) gerados devido ao janelamento do sinal, que ocorre tanto na geração das IMFs, quanto na aplicação da transformada de Hilbert. Neste trabalho, os autores concluíram que a utilização da SVM pra predição das IMFs antes da aplicação da transformada de Hilbert permite a redução dos efeitos de borda no espectro de Hilbert.

Uma avaliação comparativa entre o algoritmo EMD e sua evolução, EEMD, é feita em (44) num contexto de diagnóstico de falhas em rotores de máquinas rotativas. Através deste trabalho, os autores verificaram que o EEMD é capaz de gerar modos de vibração mais próximos da realidade quando comparados com o EMD. No entanto, esse comparativo é feito tomando-se como base a proximidade do espectro obtido a partir transformada rápida de Fourier (*Fast Fourier Transform*, FFT).

Em (35), os autores utilizaram o CEEMD combinado com teoria da correlação para avaliação de falhas em rolamentos, ressaltando a capacidade do CEEMD em superar os efeitos de mixagem de modos e *aliasing* quando comparado ao EMD, embora com um maior custo computacional.

A utilização da THH em ensaios não destrutivos com ultrassom podem ser encontrados nos trabalhos como (45-47), que analisaram, respectivamente, o uso da THH para melhorar resolução dos imageamento obtido usando a técnica pulso-eco, melhorias em inspeções de materiais poliméricos, que possuem alto poder de atenuação de sinais acústicos, e avaliação da THH em sinais obtidos através da técnica pulso-eco em fibra de carbono, visando identificar características e defeitos locais com base no espectro marginal de Hilbert.

Em (48), os autores realizam uma comparação da THH com a decomposição do sinal em *chirplets* (em inglês, *Chirplet Signal Decomposition*, CSD), identificando a THH como uma técnica eficaz para detecção de falhas, classificação de sinais e reconhecimento de padrões.

Embora diversos trabalhos tenham utilizado a THH, a sua utilização com ensaios não destrutivos com base em ultrassom, particularmente pela técnica TOFD, ainda carece de substância.

3.3 Classificação de séries temporais

A classificação de séries temporais consiste em atribuir um rótulo a um sinal no domínio do tempo, permitindo, portanto, a determinação de maneira probabilística do pertencimento daquele sinal a uma determinada classe.

Os atributos obtidos a partir da aplicação da THH, ainda no domínio temporal, podem alimentar um classificador baseado em rede neural artificial desde que corretamente organizados para tal.

Uma etapa adicional, anterior à etapa de classificação, consiste na redução da quantidade de atributos visando não somente reduzir o tempo computacional no processo de classificação, mas também a utilização de atributos que de fato contribuam para tal processo. Uma das ferramentas mais antigas e mais utilizadas (49) é a Análise de Componentes Principais (PCA).

3.3.1 Análise de Componentes Principais (PCA)


Análise de Componentes Principais (ACP) (em inglês, *Principal Component Analysis*, PCA) permite, através de uma transformação linear ortogonal, a conversão de um dado conjunto de observações num conjunto de vetores linearmente não correlacionadas conhecidos como *componentes principais*.

Seja uma matriz $\mathbf{X}_{m \times n}$, onde m é o número de realizações e n número de atributos. As componentes principais são os autovetores da matriz quadrada $\mathbf{X}^T \mathbf{X}$, ordenados de maneira decrescente de acordo com a amplitude dos seus correspondentes autovalores. No caso de haver mais atributos do que realizações (isto é, $n > m$), apenas os m autovetores com valores não-nulos devem ser utilizados. Para este caso, é possível obter as componentes principais de maneira mais eficiente através da matriz $m \times m$ $\mathbf{X} \mathbf{X}^T$, utilizando o fato de que se v é um autovetor de $\mathbf{X} \mathbf{X}^T$, então $\mathbf{X}^T v$ é um autovetor de $\mathbf{X}^T \mathbf{X}$ com o mesmo autovalor.

Uma vez que os componentes principais foram obtidos, o número de atributos pode ser reduzido de n para k , onde k representa os primeiros componentes principais. A Figura 3.3 mostra os autovalores *versus* componentes principais para um conjunto de

dados exemplo, gráfico conhecido usualmente como *scree plot*, e que é útil na determinação da quantidade de componentes principais a serem utilizadas para uma adequada redução dimensional. O termo *variância explicada* visto no eixo das ordenadas representa a soma dos quadrados dos valores do *desvio explicado* que é, por sua vez, definido para um ponto (x, y) como sendo a distância vertical entre o valor previsto de y e a reta horizontal que passa pela média amostral, ou seja, $\hat{y} - \bar{y}$.


Figura 3.3. *Scree plot* da Variância explicada *versus* número de componentes principais.



Fonte: Elaborada pelo autor.

Algumas regras de bolso podem auxiliar na determinação da quantidade necessária de componentes principais. Uma delas recomenda a escolha do número de componentes com base no joelho da curva o que, no gráfico acima, representa 1 (um) componente principal, que contém cerca de 80% da variância dos dados. Alternativamente, pode-se utilizar o diagrama de Pareto para determinar a quantidade de componentes que representem um valor adequado de variância, como ilustrado na Figura [3.4](#).

Figura 3.4. Diagrama de Pareto da Variância explicada *versus* número de componentes principais.



Fonte: Elaborada pelo autor.

Convém salientar que, a depender do conjunto de dados escolhidos, o joelho pode não estar tão evidente, sendo, portanto, a análise do diagrama de Pareto mais apropriada.

3.3.2 Redes Neurais Artificiais (RNA)

Redes neurais artificiais são modelos computacionais inspirados em neurônios biológicos que permitem o aprendizado de máquina e o reconhecimento de padrões a partir da experiência. O neurônio, como unidade básica desta rede, possui uma função não-linear de ativação, $h(\cdot)$, e a sua saída, y , é dada por

$$y = h\left(\sum_{i=1}^n w_i x_i + b_i\right), \quad (3.23)$$

onde x_i representa a entrada do neurônio e w_i e b_i são o peso sináptico e o *bias*, respectivamente, para cada entrada.

A determinação da função a ser utilizada pode impactar no processo de treinamento e no desempenho da rede neural. Diversas são as funções de ativação documentadas

na literatura e disponíveis em arcabouços de treinamento de redes neurais, sendo a função sigmoide (em inglês, *sigmoid function*) uma das mais usadas (50). Para classificadores multi-classes, como neste trabalho, a função Softmax torna-se a generalização da função sigmoide apropriada (51), sendo definida como:

$$P(y = j|\theta^i) = \frac{e^{\theta^i_j}}{\sum_{k=0}^K e^{\theta^i_k}}, \quad (3.24)$$


onde $\theta = w_0x_0 + w_1x_1 + \dots + w_kx_k = \sum_{i=0}^k w_ix_i = w^T x$.

3.3.2.1 Perceptron multicamadas (MLP)

Em redes do tipo *perceptron* multicamadas (do inglês, *multilayer perceptron*, MLP) utilizadas em aprendizado supervisionado, comumente se utiliza o algoritmo *backpropagation* para adaptação dos pesos sinápticos. O processo pode ser compreendido em duas fases: (i) *feed-forward*, em que os dados apresentados percorrem a rede da entrada até a saída, e (ii) *feed-backward*, em que o erro obtido com base na diferença entre o valor real apresentado à rede e o valor atual da saída permite a atualização dos pesos sinápticos. O processo é repetido diversas vezes até que o erro seja minimizado. Convém salientar a importância da inicialização aleatória dos pesos sinápticos.

A arquitetura de uma RNA MLP com dois neurônios de entrada, três neurônios na camada oculta e um neurônio na saída pode ser visto na Figura 3.5

Figura 3.5. Arquitetura de uma rede neural do tipo MLP.



Fonte: Elaborada pelo autor.

Diversos algoritmos permitem a minimização do erro citada anteriormente, entre eles está o gradiente conjugado escalonado (em inglês, *Scaled Conjugate Gradient*, SCG)

descrito em 1993 por (52) e utilizado neste trabalho.

3.3.3 Dilema viés-variância

A obtenção de um modelo estatístico representante de um determinado fenômeno, seja ele físico, biológico, econômico ou social torna-se interessante na medida que pode fornecer subsídios para a interpretação e compreensão da realidade. Dada uma resposta quantitativa Y e uma quantidade p de preditores de X , é possível assumir uma relação geral em que:

$$Y = f(X) + \epsilon, \quad (3.25)$$

onde ϵ é um termo que representa um erro sistemático aleatório independente de X e que possui média zero, e f é uma função desconhecida.

A estimação de f tem por objetivo a obtenção de um modelo que represente o comportamento de um dado fenômeno e permita, por conseguinte, a predição e/ou inferência acerca de Y , podendo então ser denotada por:

$$\hat{Y} = \hat{f}(X) + \epsilon. \quad (3.26)$$

Tomando-se o quadrado da média da diferença entre Y e $\hat{Y}$, tem-se:

$$E(Y - \hat{Y})^2 = E[f(X) + \epsilon - \hat{f}(X)]^2 \quad (3.27)$$

$$= \underbrace{[f(X) - \hat{f}(X)]^2}_I + \underbrace{Var(\epsilon)}_{II}, \quad (3.28)$$

sendo possível afirmar que a acurácia de $\hat{Y}$ como um preditor de Y está relacionada com dois tipos de erros, acima identificados pelos termos I e II. O erro I, conhecido como *erro redutível*, assim chamado pois pode ser reduzido de a partir da escolha de um modelo estatístico adequado, e o *erro irredutível* que, devido a sua independência de X , não pode ser predito pelo mesmo.

Tomando-se o caso particular de uma realização x_0 , após manipulação algébrica é

possível provar que:

$$E[(y_0 - \hat{f}(x_0))^2] = Var[\hat{f}(x_0)] + \{Viés[\hat{f}(x_0)]\}^2 + Var(\epsilon). \quad (3.29)$$

O termo $E[(y_0 - \hat{f}(x_0))^2]$, usualmente conhecido como erro quadrático médio (em inglês, *mean squared error*, MSE), será tanto menor quanto melhor o modelo estatístico se aproximar da realidade. É importante notar ainda que seu valor depende de dois termos inerentemente positivos denominados variância de $\hat{f}(x_0)$, $Var[\hat{f}(x_0)]$, e viés (ou, em inglês, *bias*) de $\hat{f}(x_0)$, $\{Viés[\hat{f}(x_0)]\}^2$, por isso, MSE não pode assumir um valor menor que $Var(\epsilon)$.

A variância de um modelo está associada com o quanto o mesmo é afetado (varia) caso seja treinado com um conjunto de dados de treinamento diferente. Por outro lado, o viés se refere a um erro associado à aproximação de um problema do mundo real, usualmente complexo, por um modelo mais simples, como por exemplo, a aproximação de um fenômeno não-linear a partir de um modelo linear.

O dilema (ou relação de compromisso) entre viés e variância (em inglês, *bias-variance tradeoff*), surge, nesse contexto, pois é comum que modelos que apresentam baixo viés, tendam a apresentar alta variância e vice-versa (53), sendo então necessário estabelecer um equilíbrio ótimo entre ambas quantidades.

3.3.4 Validação Cruzada

Validação cruzada (VC) (em inglês, *cross validation*, CV) é um método de reamostragem de dados (em inglês, *re-sampling methods*) que permite uma estimativa mais adequada da capacidade de generalização de um modelo estatístico, a partir da avaliação da taxa de erro do conjunto de testes.

Uma das abordagens mais utilizadas para este fim é conhecida como *abordagem através de conjunto de validação* (ou, em inglês, *validation set approach*) e baseia-se na divisão do conjunto de amostras original em dois subconjuntos distintos, um que é utilizado para o ajuste do modelo estatístico e outro que é utilizado para avaliar a taxa de erro do modelo ajustado (conjunto de validação). No entanto, essa abordagem apresenta

duas desvantagens nítidas:

- 1) a taxa de erro obtida com a utilização do conjunto de validação pode apresentar uma alta variância, dependendo de como as amostras foram subdivididas;
- 2) apenas uma parte do conjunto original de amostras é utilizado para ajuste do modelo estatístico, o que tende a piorar o desempenho do modelo, na medida que menos amostras são usadas.

No sentido de contornar esses problemas, algumas abordagens foram derivadas a partir da validação através de conjunto de validação e serão descritas a seguir.

3.3.4.1 Método *leave-one-out*

Neste método, o conjunto de dados é dividido em dois subconjuntos também, no entanto, o conjunto utilizado para a validação possui apenas uma amostra, (x_1, y_1) , enquanto o conjunto de teste possui $n - 1$ elementos, ou seja, $\{(x_2, y_2), \dots, (x_n, y_n)\}$, resolvendo, portanto, o problema de um conjunto reduzido de dados para ajuste do modelo.

Por outro lado, a estimativa do erro feita a partir de uma única amostra mostra-se inadequada devido sua alta variância, uma vez que é baseada em apenas uma observação. Nesse sentido, seleciona-se $\{(x_2, y_2)\}$ como conjunto de validação e obtém-se uma nova estimativa de erro. Repetindo esse processo n vezes, é possível obter uma estimativa através da média dos erros.

Vale ressaltar que este método pode exigir um alto custo computacional, uma vez que envolve o ajuste dos parâmetros do modelo n vezes.

3.3.4.2 Método *k-Fold*

Alternativamente, pode-se dividir o conjunto original de dados em k grupos, também conhecidos como *folds* com tamanho aproximadamente igual. Neste caso, o primeiro *fold* é utilizado como conjunto de validação e os demais são utilizados para treinamento.

Nesse sentido, vê-se que o método *leave-one-out* é um caso particular do método

k-fold, quando $k = n$, sendo n o número total de amostras. Valores típicos para k estão entre 5 e 10 (26).

3.3.5 Avaliação do modelo

Quando se trabalha num problema de classificação, a avaliação de um modelo estatístico (em inglês, *model assessment*) tem em vista verificar o seu desempenho em classificar os dados dentro das suas respectivas classes. Ressalta-se ainda que a avaliação de modelos estatísticos se faz necessária, uma vez que não existe um melhor modelo que seja universal (53). Nesse sentido, os parâmetros de avaliação permitem a seleção de um modelo mais apropriado para cada aplicação. Com esse fim, há diversas ferramentas e parâmetros disponíveis que permitem a análise sob diferentes ângulos acerca do modelo. Algumas das ferramentas mais conhecidas e utilizadas são a matriz de confusão — e os parâmetros dela derivada—, e curva COR, descritas a seguir.

I) Matriz de confusão

A matriz de confusão, também conhecida como matriz de erros, é uma ferramenta útil na avaliação de modelos de classificação. Através dela é possível verificar o comportamento do classificador segundo os valores corretos e incorretos na predição realizada pelo modelo. Convém diferenciar, no entanto, que valores corretos são denominados usualmente de *verdadeiros positivos* (V_P) e *verdadeiros negativos* (V_N) quando um classificador consegue acertadamente classificar tanto o que é, quanto o que não é, respectivamente. Por outro lado, quando um classificador erroneamente classifica o que é e o que não é, dão-se as denominações de *falsos positivos* (F_P) e *falsos negativos* (F_N), respectivamente. A Figura 3.6 mostra um exemplo de matriz de confusão para um classificador binário, em que pretende-se classificar a existência de defeito genérico.

Figura 3.6. Matriz de confusão para um classificador binário defeito/sem-defeito.

		Classe predita	
		Defeito	Sem defeito
Classe real	Defeito	V_P	F_P
	Sem defeito	F_N	V_N

Fonte: Elaborada pelo autor.

É possível estender essa abordagem para classificadores multi-classes apenas incluindo as classes adicionais na matriz.

A partir das informações obtidas da matriz de confusão, é possível obter medidas que representem a capacidade do classificador em corretamente classificar somente exemplos positivos, somente exemplos negativos ou ainda outras combinações. Tais combinações serão detalhadas a seguir.

II) Sensibilidade, Precisão, Acurácia, Especificidade e F1-score

- **sensibilidade** (S), também denominada revocação, ou ainda *recall* é a capacidade de um modelo em identificar numa determinada classe, elementos que, de fato, pertençam a essa classe. É definida como:

$$S = \frac{V_P}{V_P + F_N}; \quad (3.30)$$

- **especificidade** (E) é a capacidade de um modelo em identificar numa determinada classe, os elementos que, de fato, não pertençam a essa classe. É definida como:

$$E = \frac{V_N}{V_N + F_P}; \quad (3.31)$$

- **acurácia** (A) é a capacidade de um modelo fornecer resultados corretos. É definida

como:

$$A = \frac{V_P + V_N}{V_P + V_N + F_P + F_N}; \quad (3.32)$$

- **precisão (P)** é a capacidade de um modelo em identificar positivamente a condição relevante (defeito, por exemplo). É definida como:

$$P = \frac{V_P}{V_P + V_N + F_P + F_N}; \quad (3.33)$$

- **f1-score (F)** é uma média harmônica que leva em consideração a sensibilidade e a precisão. É definida como:

$$F = 2 \times \frac{P \times S}{P + S}. \quad (3.34)$$

Uma outra métrica descrita na literatura é o produto das eficiências (PE) ou, em inglês, *efficiency product* (EP), definido como:


$$PE = \sqrt[N]{\prod_{i=1}^N E_{fi}}, \quad (3.35)$$

onde a eficiência $E_{fi} = 1$ indica 100% de acurácia na classificação e N é o número de classificações realizadas.

III) Curva Característica de Operação do Receptor (COR)

A curva Característica de Operação do Receptor (COR) ou, em inglês, *Receiver Operating Characteristic* (ROC) é uma representação gráfica que ilustra o desempenho de um sistema de classificação. No eixo das ordenadas, tem-se a sensibilidade (S) ou a taxa de verdadeiros positivos (TVP), enquanto no eixo das abscissas, tem-se a taxa de falsos positivos (TFP) ou 1 - especificidade (1-E). A Figura 3.7 ilustra um exemplo de curva COR para um classificador de três classes. Através desta curva é possível verificar que o classificador apresentou um desempenho satisfatório para as três classes, em especial para a classe 1.

Figura 3.7. Exemplo de uma curva Característica de Operação do Receptor (COR) para um classificador de três classes.



Fonte: Elaborada pelo autor.


METODOLOGIA

Este capítulo descreve os aspectos metodológicos deste trabalho, detalhando o procedimento experimental para a obtenção dos dados, o corpo de prova utilizado nos ensaios, além das etapas de construção e definição dos atributos usados no processo de classificação, os cenários de simulação e os parâmetros de avaliação de desempenho do classificador.

Com o intuito de fornecer uma base sólida e robusta acerca das técnicas utilizadas neste trabalho, uma ampla revisão bibliográfica baseada na análise de artigos e periódicos de congressos nacionais e internacionais, além da consulta de uma bibliografia especializada em ensaios não destrutivos e engenharia de soldagem, foi realizada e pode ser revisitada a qualquer momento nos Capítulos 2 e 3.

Nesse sentido, as etapas que compreendem este trabalho podem ser sintetizadas e visualizadas com auxílio do diagrama da Figura 4.1.

Figura 4.1. Cadeia de processamento de sinais sugerida.



Fonte: Elaborada pelo autor.

Inicialmente, os *dados experimentais* são submetidos a etapa de pré-processamento, objetivando adequar os sinais para as etapas subsequentes, que no diagrama estão englobadas como etapas de *extração de características*. Embora tais etapas sejam também comumente consideradas como etapas de pré-processamento, a divisão exibida na imagem procura enfatizar as técnicas usadas para a extração de características. Dentro dessas etapas, o primeiro passo compreende a aplicação do algoritmo de decomposição empírica em modos que, neste trabalho, serão três distintas: EMD, EEMD e CEEMDAN, utilizadas de

maneira independente. Sobre as IMFs obtidas a partir da aplicação dos diferentes modos de decomposição, calcula-se a transformada de Hilbert, com o objetivo de obter a energia e frequência instantâneas de cada uma das IMFs, sendo, portanto, essas variáveis as que serão consideradas como características do sinal de interesse. A fim de realizar a redução dimensional, a PCA é aplicada. A última etapa corresponde a utilização de uma rede neural para resolver o problema de classificação e possibilitar o diagnóstico automatizado das condições de interesse.


Alguns trabalhos ([12], [13], [28]) têm aplicado uma cadeia de processamento similar, embora utilizem técnicas diferentes para extração de características.

4.1 Procedimento experimental

O arranjo experimental utilizado é o mesmo de ([28]) e pode ser visto na Figura 4.2. Neste ensaio, o gerador de pulsos é o equipamento responsável pela geração dos sinais ultrassônicos que serão inseridos no material. O processo de conversão eletromecânica é feita pelo transdutor piezoelétrico de feixe angular. O mesmo transdutor pode ser utilizado para captar as ondas refletidas e refratadas pelo material que posteriormente são enviadas a um osciloscópio e computador pessoal. As especificações dos equipamentos utilizados, bem como os valores das taxas de amostragem para o experimento descrito a seguir são:

- Transdutor Olympus Panametrics® C543-SM ([54]), sapata acrílica com ângulo de incidência igual a 45° , frequência central de 5 MHz, tamanho do cristal 3 mm, comprimento de onda $\lambda = 648\mu m$;
- Gerador de pulsos Olympus Panametrics® 5077PR ([55]), excitação senoidal ($V_p = 5V$) e ganho de 10 dB no canal de recepção;
- Osciloscópio Tektronix TDS-2024B ([56]) com frequência de amostragem de 250 MHz.

Figura 4.2. Ilustração do arranjo experimental usado para obtenção dos dados.




Fonte: Elaborada pelo autor.

Foi utilizado um corpo de prova de aço carbono soldado através de uma combinação de técnicas de soldagem MIG (*Metal Inert Gas*), TIG (*Tungsten Inert Gas*) e eletrodo revestido) (13). Durante o procedimento foram inseridos os defeitos ao longo do cordão de solda de maneira controlada, mantendo-se uma região em defeito. As condições consideradas foram: falta de fusão (FF), inclusão de escória (IC), falta de penetração e trinca (FPTC) e porosidade (PO). A verificação dessas condições foi realizada com base em exame radiográfico. As características do corpo de prova podem ser resumidas em:


- **Material:** Aço carbono SAE 1020
- **Solda:** MIG, TIG e eletrodo revestido
- **Dimensões (mm):** 1000 x 500 x 15,5
- **Condições:** sem defeito (SD), falta de fusão (FF), inclusão de escória (IC), porosidade (PO) e falta de penetração/trinca (FPTC)

A Figura 4.3 mostra a disposição dos defeitos inseridos no corpo de prova.

Figura 4.3. Corpo de prova usado nos ensaios.

Fonte: Cedida pelo GPEND-IFBA.

Após a execução dos testes é possível visualizar as formas de onda para as condições consideradas. A Figura 4.4 mostra uma realização típica obtida experimentalmente para cada condição considerada neste trabalho.

Figura 4.4. Formas de onda típicas para as diversas condições de interesse.

Fonte: Elaborada pelo autor.

No total foram obtidas 200 realizações para cada uma das 5 condições, totalizando 1.000 (5×200) realizações coletadas, cada uma com 2.500 amostras temporais.


Após a normalização pelo valor máximo, as realizações foram submetidas aos três diferentes algoritmos de decomposição (EMD, EEMD e CEEMDAN), cujo critério de parada estabelecido baseia-se na tolerância relativa igual a 0,2. A utilização deste critério gera um número variável de IMFs, por isso, visando a uniformização dos dados, optou-se pela utilização do menor número observado entre todas as realizações ($n = 7$). Para os algoritmos EEMD e CEEMDAN foram ainda considerados números de conjuntos (*ensembles*) iguais a $N_{ens} = 10, 50$ e 100 , enquanto o desvio padrão do ruído gaussiano variou entre $w_n = 0, 1, 0, 2$ e $0, 4$.

Em seguida, a aplicação da transformada de Hilbert permite a obtenção das frequências e energias instantâneas para cada uma das 7 IMFs de acordo com as expressões em (3.18), o que resulta, para cada condição de interesse, em dois vetores E_{inst} e f_{inst} com 17.500×200 elementos, totalizando, para todas as condições de interesse, numa matriz de 35.000 (2×17.500) características para cada uma das 1.000 (5×200) realizações.

Com a finalidade de mitigar os problemas relacionados a variância estatística devido a um elevado número de atributos, quando comparado ao número de realizações, o conjunto de dados foi submetido a redução dimensional utilizando PCA, salientando-se, porém, que a PCA aplica-se unicamente à amplitude (ou energia). A fim de obter um conjunto de vetores que representassem uma variância explicada maior do que 95% para todas as condições de interesse, selecionou-se um número de 200 vetores principais o que, comparado com a quantidade de atributos iniciais (17.500), representa uma redução dimensional significativa, visto que o conjunto torna-se 87,5 vezes menor.


Ademais, com o intuito de melhor avaliar a capacidade de generalização do modelo, o conjunto de dados foi particionado em cinco subconjuntos para aplicação da validação cruzada *k-fold* ($k = 5$). Dos cinco *folds* gerados, cada rodada de treinamento utilizou 60% para treinamento, 20% para teste e 20% para validação, o que equivale a 3, 1 e 1 *folds*, respectivamente.

A Figura 4.5 ilustra as etapas iniciais de pré-processamento utilizando os três diferentes algoritmos de decomposição de maneira independente.

Figura 4.5. Fluxo de pré-processamento dos dados.

Fonte: Elaborada pelo autor.


Por outro lado, a Figura 4.6 elucida as etapas de organização e particionamento do conjunto de dados para utilização da validação cruzada e finalmente utilização no treinamento do classificador. O conjunto original com 1.000 realizações foi subdividido em 5 grupos cada um com a mesma quantidade de realizações para cada uma das condições de interesse. As realizações foram então aleatorizadas e utilizadas no processo de treinamento da rede neural.

Figura 4.6. Organização dos dados para classificação após PCA.

Fonte: Elaborada pelo autor.

Os conjuntos de dados acima originados alimentaram uma rede neural do tipo perceptron multicamadas, cujo algoritmo de treinamento utilizado fundamenta-se no gradiente conjugado escalonado. O número de neurônios na camada oculta, N_h , variou entre 1 e 13, faixa escolhida inicialmente para possibilitar a comparação com trabalhos na literatura. A Figura 4.7 ilustra a arquitetura da rede neural utilizada.

Figura 4.7. Arquitetura da rede neural do tipo MLP utilizada neste trabalho.



Fonte: Elaborada pelo autor.

4.2 Parâmetros de avaliação do modelo

Para cada rodada de treinamento, cinco parâmetros de desempenho foram calculados (acurácia, precisão, sensibilidade, especificidade e f1-score), além do produto das eficiências como média geométrica das acurácias. A Figura 4.8 mostra os parâmetros calculados e organizados para cada rodada, bem como as suas médias.

Figura 4.8. Parâmetros de desempenho calculados para cada rodada de treinamento e seus valores médios.

Acurácia média	Acurácia Rodada 1	Acurácia Rodada 2	...	Acurácia Rodada 5
Precisão média	Precisão Rodada 1	Precisão Rodada 2	...	Precisão Rodada 5
Sensibilidade média	Sensibilidade Rodada 1	Sensibilidade Rodada 2	...	Sensibilidade Rodada 5
Especificidade média	Especificidade Rodada 1	Especificidade Rodada 2	...	Especificidade Rodada 5
F1-score média	F1-score Rodada 1	F1-score Rodada 2	...	F1-score Rodada 5
PE média geométrica	PE Rodada 1	PE Rodada 2	...	PE Rodada 5

Fonte: Elaborada pelo autor.

RESULTADOS E DISCUSSÃO


Os resultados para os diversos cenários apresentados no Capítulo 4 são expostos neste capítulo. Inicialmente são apresentadas as funções de modo intrínseco obtidas para os três algoritmos de decomposição — EMD, EEMD e CEEMDAN, seguidas dos seus respectivos espectros de Hilbert, o que configura a transformada de Hilbert-Huang dos sinais de interesse. Logo após, a análise de componentes principais é aplicada com o objetivo de reduzir a dimensionalidade dos dados, favorecendo possivelmente melhorias no processo de classificação. Por fim, são apresentados os parâmetros usados no modelo de classificação e os resultados atinentes ao processo de classificação, bem como uma breve discussão acerca dos parâmetros de desempenho para os diversos cenários.

5.1 Obtenção das funções de modo intrínseco

As IMFs foram obtidas utilizando os algoritmos dispostos no Anexo A utilizados em diversos trabalhos (36). O critério de parada usado baseia-se na tolerância relativa igual a 0,2. No entanto, observou-se que diferentes realizações para os diferentes tipos de defeitos geram um número variável de IMFs (entre 7 e 12, além do resíduo) quando este critério é utilizado, sendo necessário, por esse motivo, que as IMFs excedentes fossem descartadas.

A Figura 5.1 mostra IMFs relativas a uma realização das diversas condições de defeito sobrepostas num mesmo gráfico, geradas utilizando o algoritmo EMD aplicado a uma única realização. Convém salientar que a última IMF de cada defeito é, na verdade, seu resíduo. Nesse sentido, para as condições inclusão de escória, porosidade, falta de penetração/trinca a IMF 9 é o seu respectivo resíduo, enquanto para a condição sem defeito, a IMF 10 deve ser entendida como o resíduo. Além disso, para a realização considerada, a condição falta de fusão apresentou 10 IMFs, sendo a IMF 11 o seu resíduo.


Figura 5.1. IMFs obtidas através do algoritmo EMD considerando uma realização típica de cada condição de interesse.



Fonte: Elaborada pelo autor.


Em contrapartida, as gráficos das Figuras 5.2 a 5.5 mostram as IMFs obtidas utilizando o algoritmo EEMD e CEEMDAN considerando variações nos parâmetros de amplitude do ruído gaussiano ($w_n = 0, 1, 0, 2$ e $0, 4$) e também no número de *ensembles* ($N_{ens} = 10, 50$ e 100).

Figura 5.2. IMFs obtidas através do algoritmo EEMD para $w_n = 0,2$ e $N_{ens} = 10, 50$ e 100 , considerando uma realização típica de cada condição de interesse.




Fonte: Elaborada pelo autor.

Figura 5.3. IMFs obtidas através do algoritmo EEMD para $N_{ens} = 50$ e $w_n = 0, 1, 0, 2$ e $0, 4$, considerando uma realização típica de cada condição de interesse.




Fonte: Elaborada pelo autor.

Figura 5.4. IMFs obtidas através do algoritmo CEEMDAN para $w_n = 0,2$ e $N_{ens} = 10, 50$ e 100 , considerando uma realização típica de cada condição de interesse.



Fonte: Elaborada pelo autor.


Figura 5.5. IMFs obtidas através do algoritmo CEEMDAN para $N_{ens} = 50$ e $w_n = 0, 1, 0, 2$ e $0, 4$, considerando uma realização típica de cada condição de interesse.



Fonte: Elaborada pelo autor.

A fim de estabelecer um comparativo entre os sinais obtidos através dos diferentes algoritmos de decomposição, a Figura 5.6 mostra as primeiras IMFs obtidas de uma realização típica da condição de interesse, considerando $w_n = 0,2$ e $N_{ens} = 50$ para EEMD e CEEMDAN.

Figura 5.6. IMFs obtidas a partir de uma realização típica utilizando EMD, EEMD e CEEMDAN.



Fonte: Elaborada pelo autor.

Através das Figuras 5.1 a 5.6 é possível notar, primeiramente, que há diferença na quantidade de IMFs geradas para os três diferentes algoritmos entre as várias condições de interesse analisadas. Além disso, um mesmo algoritmo pode também gerar um número variável de IMFs dentro de uma mesma condição de interesse, situação que pode interferir no desempenho do classificador, mas que pode ser mitigada por intermédio de uma escolha apropriada do número de IMFs.

Em segundo lugar, é possível observar, como esperado, que as primeiras IMFs correspondem aos modos de vibração de maior frequência do sinal de interesse, tornando-se mais perceptível a existência da onda lateral e eco de fundo (ver Figura 2.1) apenas nas IMFs de ordem superior. Vale enfatizar que, diferentemente do ilustrado na figura supracitada, que mostra uma condição hipotética e ideal onde o defeito possui dimensões significativas a ponto de criar oscilações perceptíveis entre as ondas lateral e eco de fundo, o que as IMFs aludidas parecem ilustrar é que a influência dos defeitos está mais presente no formato da onda lateral e eco de fundo, agindo, deste modo, como um modulador desses sinais. Diante da complexidade dos mecanismos de propagação da onda no interior do material, torna-se difícil realizar uma interpretação mais precisa.

A Figura 5.6 permite ainda examinar a influência do ruído deliberadamente adicionado ao sinal de interesse nos casos em que os algoritmos EEMD e CEEMDAN foram utilizados, quando comparados ao algoritmo EMD. A ausência de tendência na IMF 10 (no CEEMDAN para todas as condições e no EEMD para algumas condições) indica que tais algoritmos obtiveram mais modos de vibração, o que pode ser interpretado como um indicativo de que a decomposição a partir do algoritmo EMD pode ter sofrido de mixagem de modos, ou seja, os modos de vibração não foram corretamente decompostos.

Além disso, é importante mencionar que os diferentes algoritmos apresentam tempos de execução diferentes para a geração das funções de modo intrínseco. A Tabela 5.1 mostra o tempo necessário para obtenção das IMFs para uma única realização, utilizando os três algoritmos de decomposição investigados neste trabalho, quando a plataforma de simulação baseia-se num processador Intel® Core™ i5-7200 CPU @ 2.50GHz, 8GB de memória RAM. Para os algoritmos EMD e CEEMDAN considerou-se o número de conjuntos $N_{ens} = 10, 50$ e 100 .

Tabela 5.1. Tempo médio, em segundos, de execução dos algoritmos para obtenção das IMFs de uma única realização, considerando para os algoritmos EEMD e CEEMDAN.

Tempo para geração das IMFs por realização (s)	EMD	0,07			
	EEMD	0,1	0,2	1,0	2,1
		0,2	0,2	0,9	6,1
		0,4	0,2	1,2	1,7
	CEEMDAN	0,1	0,7	3,0	5,9
		0,2	0,8	2,7	2,4
		0,4	0,7	2,8	5,3
	w_n N_{ens}		10	50	100

Fonte: Elaborada pelo autor.


Não obstante em (36), os autores reivindicarem um menor número de iterações com o algoritmo proposto (o que reduziria o custo computacional), não foi observado um desempenho superior (mais rápido) do CEEMDAN neste aspecto. No entanto, deve-se ponderar que, neste trabalho, o número de IMFs obtidas através do algoritmo CEEMDAN foi maior do que para o algoritmo EEMD, diferentemente do exposto em (36), quando os sinais de interesse eram sinais de eletrocardiograma (ECG), o que poderia justificar os números da Tabela 5.1.

Salienta-se ainda que o objetivo dessa comparação não é o de avaliar o desempenho dos algoritmos, mas sim de fornecer ao leitor uma ideia geral acerca do tempo de execução para obtenção das IMFs com os três diferentes algoritmos.

5.2 Aplicação da transformada de Hilbert

Após a geração das IMFs, aplicou-se a transformada de Hilbert que permite obter as frequências instantâneas e as amplitudes (ou energias) instantâneas de cada uma delas. A Figura 5.7 mostra os espectros de Hilbert relativos às diversas condições de defeito com todas as IMFs sobrepostas num mesmo gráfico, quando as tais foram geradas através do método de decomposição EMD.

Figura 5.7. Sobreposição dos espectros de Hilbert de todas as IMFs para a condição sem defeito (a) e para as condições com defeito (b-e), quando tais IMFs foram geradas a partir do EMD.




Fonte: Elaborada pelo autor.

É perceptível a existência de modos de vibração correspondentes à onda lateral e também ao eco de fundo. Além do mais, os diferentes defeitos produziram alterações na intensidade e formato nesses modos, o que poderia ser interpretado fisicamente pelos fenômenos ondulatórios de interferências construtivas e destrutivas entre as ondas difratadas e refletidas e suas interações com o defeito. É possível observar também o efeito de borda, especialmente nas condições IC, PO e FPTC.


Por outro lado, as Figuras 5.8 a 5.11 mostram os espectros de Hilbert obtidos sobre as IMFs geradas a partir dos métodos de decomposição EEMD e CEEMDAN, respectivamente, considerando variações nos parâmetros w_n e N_{ens} . A fim de facilitar a análise comparativa entre as diversas condições, os gráficos mostram os espectros sobrepostos de todas as IMFs de cada condição.

Figura 5.8. Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método EEMD com três diferentes valores de N_{ens} e $w_n = 0, 2$.




Fonte: Elaborada pelo autor.

Figura 5.9. Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método EEMD com três diferentes valores de w_n e $N_{ens} = 50$.




Fonte: Elaborada pelo autor.

Figura 5.10. Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método CEEMDAN com três diferentes valores de N_{ens} e $w_n = 0,2$.



Fonte: Elaborada pelo autor.

Figura 5.11. Sobreposição dos espectros de Hilbert de todas as IMFs das condições estudadas neste trabalho, quando tais IMFs foram obtidas através do método CEEMDAN com três diferentes valores de w_n e $N_{ens} = 50$.



Fonte: Elaborada pelo autor.

A partir das Figuras 5.8 e 5.9, nota-se que existe um efeito maior sobre o espectro com as alterações nos valores de w_n em comparação com alterações nos valores de N_{ens} , embora um aumento no número de *ensembles* melhore levemente a nitidez das regiões observadas. Quando há a variação de w_n para um mesmo valor de N_{ens} (Figura 5.9), os espectros parecem se tornar mais nítidos à medida que a amplitude do ruído gaussiano branco aumenta. Em ambos os casos, porém, os modos de vibração relacionados à onda lateral e eco de fundo apresentam diferenças importantes entre os diversos defeitos.


No caso dos espectros obtidos a partir da HHT-CEEMDAN (Figuras 5.10 e 5.11), nota-se um espectro mais ruidoso, mas ainda diferente entre as diversas condições. Também ocorre aqui o efeito de aumento da nitidez em função do aumento do número de *ensembles*, que pode ser explicado pelo valor do desvio explicitado na Eq. 3.11, na medida que para maiores valores, tal desvio (diferença entre o sinal a ser decomposto e sua IMF) é reduzido, considerando w_n constante.

5.3 Análise de componentes principais


A obtenção das frequências instantâneas e energias instantâneas eleva a dimensão dos dados que originalmente apresentam 2.500 pontos no tempo em cada realização, para 35.000 pontos (2.500 pontos para cada uma das 7 frequências instantâneas e 2.500 pontos para cada uma das 7 energias instantâneas). Nesse sentido, torna-se prudente a utilização da análise de componentes principais na tentativa de reduzir a dimensionalidade dos dados e possivelmente melhorar a acurácia do processo de classificação. Convém salientar, porém, que a PCA é útil para a compactação das características de energia instantânea, pois a determinação dos vetores principais é feita com base na sua variância (amplitude). Por isso, as características de frequências instantâneas não serão utilizadas.

A Figura 5.12 mostra o diagrama de Pareto para todas as condições estudadas neste trabalho, quando apenas os atributos de energia são considerados.

Figura 5.12. Diagrama de Pareto da variância explicada *versus* número de componentes principais para os atributos de energia, ressaltando que as linhas representam a variância explicada acumulada.



(a) EMD

(b) EEMD ($w_n = 0, 2, N_{ens} = 50$)(c) CEEMDAN ($w_n = 0, 2, N_{ens} = 50$)

Fonte: Elaborada pelo autor.

Para os três algoritmos, escolheu-se um número de 200 componentes principais, o que representa mais de 95% da variância explicada em todos os casos. A partir dessa redução dimensional, o número de atributos de energia cai expressivamente de 17.500 para 200.

5.4 Classificação dos defeitos utilizando MLP-RNA

Uma rede neural do tipo *perceptron* multicamadas foi projetada para avaliar a capacidade da THH em extrair características do sinal de interesse, considerando como algoritmo de treinamento o gradiente conjugado escalonado (em inglês, *scaled conjugate*

gradient), escolhido devido a seu melhor desempenho em termos de tempo de execução, quando comparado a outros algoritmos tradicionais de otimização tais como BP e CGL (52) e até mesmo LM que, para este trabalho, apresentou um alto consumo de memória RAM, inviabilizando o seu uso. O número de neurônios na camada oculta variou entre 1 e 13, faixa escolhida inicialmente para possibilitar a comparação com outros trabalhos na literatura que utilizam uma base de dados similar. Além disso, o método de validação cruzada *k-fold* foi aplicado com o objetivo de permitir uma avaliação adequada da capacidade de generalização do classificador, e o conjunto de dados original foi particionado em 5 subconjuntos ($k = 5$), permitindo que o modelo estatístico fosse ajustado considerando 3 subconjuntos de treinamento (60% das realizações), 1 subconjunto de validação (20% das realizações) e 1 subconjunto de teste (20% das realizações), sendo todos eles alternados de modo que cada amostra fosse utilizada para treino, teste e validação em momentos distintos. Os valores dos parâmetros são obtidos a partir da média de todos os subconjuntos. A Tabela 5.2 resume parâmetros utilizados no modelo de classificação.


Tabela 5.2. Parâmetros do modelo classificador.

Tipo de RNA	MLP
Algoritmo de treinamento	Gradiente Conjugado Escalonado
Particionamento dos dados	Treinamento (60%), validação (20%) e teste (20%)
Método de reamostragem	<i>k-fold</i> ($k = 5$)
Neurônios na camada oculta	1 a 13
Número de atributos x realizações	17.500 x 200 (sem PCA), 200 x 200 (com PCA)

Fonte: Elaborada pelo autor.

Após 250 rodadas de treinamento (125 sem PCA e 125 com PCA), foi possível obter o produto das eficiências do classificador considerando uma variação da quantidade de neurônios da camada oculta, N_h , entre 1 e 13. A Figura 5.13 mostra como o produto das eficiências varia de acordo com a quantidade de neurônios na camada oculta para os melhores resultados das diversas técnicas de pré-processamento analisadas neste trabalho.

Figura 5.13. Produto das eficiências, PE , versus número de neurônios na camada oculta, N_h , para os melhores resultados (a) sem PCA e (b) com PCA, para diversas decomposições investigadas neste trabalho.




Fonte: Elaborada pelo autor.

É possível observar que o classificador conseguiu de maneira satisfatória realizar a classificação dos defeitos para os três algoritmos de decomposição considerados neste trabalho, com destaque para os métodos EEMD e CEEMDAN que alcançaram valores de $98,5 \pm 0,7\%$ e $97,4 \pm 1,4\%$, respectivamente, quando a não houve compactação dos dados, e $93,1 \pm 1,2\%$ e $92,7 \pm 0,8\%$ (EEMD e CEEMDAN, respectivamente) quando a PCA foi aplicada. Para o algoritmo EMD o produto das eficiências chegou a $95,3 \pm 2,2\%$ sem PCA e $91,0 \pm 1,3\%$ com PCA.

As Figuras 5.14a, 5.14b e 5.14c mostram como o produto das eficiências varia em função da quantidade de *ensembles*, N_{ens} , e da amplitude do ruído gaussiano, w_n , para o algoritmo EEMD quando a redução dimensional baseada em PCA não é utilizada, ao passo que as Figuras 5.14d, 5.14e e 5.14f mostram os resultados quando a PCA é aplicada.

Figura 5.14. Produto das eficiências *versus* número de neurônios na camada oculta, considerando o algoritmo EEMD com e sem PCA para diversos valores de w_n e N_{ens}




Fonte: Elaborada pelo autor.

Observa-se que os melhores resultados para os três valores de N_{ens} (10, 50 e 100), ocorre quando $w_n = 0,1$, independentemente da aplicação da redução dimensional. Porém, à medida que o número de *ensembles* aumenta, o classificador parece se tornar mais


eficiente para as condições onde a amplitude do ruído aumenta, como é possível observar nas Figuras 5.14c e 5.14f, quando $w_n = 0,4$. Apesar da redução geral do produto das eficiências quando a técnica PCA é aplicada, o comportamento do classificador segue o mesmo padrão, ainda apresentando resultados satisfatórios.

Por outro lado, as Figuras de 5.15a a 5.15f mostram a influência dos parâmetros N_{ens} e w_n nos valores do produto de eficiência do classificador quando o algoritmo CE-EMDAN é usado. Nota-se que este algoritmo sofre menos influência da variação desses parâmetros, apresentando um comportamento semelhante em todas as condições testadas, ainda que para as situações onde a redução dimensional é aplicada haja uma leve redução produto das eficiências.


Figura 5.15. Produto das eficiências *versus* número de neurônios na camada oculta, considerando o algoritmo CEEMDAN com e sem PCA para diversos valores de w_n e N_{ens}




(a)




(c)




(b)



(d)



(e)





(f)

Fonte: Elaborada pelo autor.


As Figuras 5.16 e 5.17 mostram o produto das eficiências em função dos parâmetros w_n e N_{ens} para os algoritmos EEMD e CEEMDAN, respectivamente, considerando o número de neurônios na camada oculta que gerou o maior PE em cada cenário, e ainda o uso da redução dimensional. Nota-se um comportamento mais regular (com menos influência dos parâmetros N_{ens} e w_n) quando o algoritmo CEEMDAN é utilizado em ambas as situações (com e sem PCA).

Figura 5.16. Produto das eficiências em função dos parâmetros w_n e N_{ens} para o algoritmo EEMD sem PCA (esq.) e com PCA.



Fonte: Elaborada pelo autor.

Figura 5.17. Produto das eficiências em função dos parâmetros w_n e N_{ens} para o algoritmo CEEMDAN sem PCA (esq.) e com PCA.



Fonte: Elaborada pelo autor.

É também interessante notar o efeito conjunto desses parâmetros: para valores mais altos de amplitude do ruído gaussiano e menor quantidade de número de *ensembles*, é possível inferir que o ruído inserido atrapalha o processo de treinamento. Há, porém, um efeito diferente no caso em CEEMDAN com redução dimensional, onde o menor desempenho ocorre para um menor número de *ensembles* e menor amplitude do ruído gaussiano. Uma possível causa para esse efeito estaria relacionada com um terceiro fator: a redução da atributos utilizados pela rede neural.

A Tabela 5.3 mostra em detalhes os valores dos produtos das eficiências para cada tipo de defeito para os diferentes métodos de decomposição, com e sem redução dimensional.

Tabela 5.3. Comparação usando as acurácias médias de cada condição e o produto de eficiências para diversos métodos de extração de características.

	SD	PO	IC	FPTC	FF	PE
HHT – EMD	$97,3 \pm 1,4$	$94,4 \pm 4,2$	$92,0 \pm 5,3$	$97,4 \pm 1,1$	$95,5 \pm 2,3$	95,3
HHT – EMD + PCA	$92,8 \pm 2,8$	$91,3 \pm 1,9$	$89,3 \pm 2,2$	$90,5 \pm 1,0$	$91,1 \pm 3,8$	91,0
HHT – EEMD	$98,8 \pm 1,2$	$98,9 \pm 0,6$	$97,3 \pm 1,0$	$99,0 \pm 0,9$	$98,4 \pm 1,2$	98,5
HHT – EEMD + PCA	$95,0 \pm 2,4$	$91,7 \pm 3,5$	$92,9 \pm 1,5$	$92,8 \pm 2,3$	$92,9 \pm 2,3$	93,0
HHT – CEEMDAN	$98,2 \pm 2,0$	$97,4 \pm 1,9$	$95,3 \pm 4,5$	$99,0 \pm 1,1$	$97,2 \pm 2,8$	97,4
HHT – CEEMDAN + PCA	$93,1 \pm 1,9$	$92,0 \pm 1,1$	$93,2 \pm 1,4$	$91,8 \pm 5,4$	$93,6 \pm 1,7$	92,7

Fonte: Elaborada pelo autor.

Por outro lado, a Tabela 5.4 mostra os valores para as diferentes métricas de


acurácia, sensibilidade, especificidade e f1-score, considerando os melhores resultados para cada método de decomposição, sem e com redução dimensional.

Tabela 5.4. Avaliação da classificação com base nos parâmetros de acurácia, sensibilidade, especificidade e f1-score, considerando dados de teste.

Acurácia				Acurácia (PCA)			
SD	97,3%	98,8%	98,2%	SD	92,9%	95,0%	93,1%
PO	94,4%	98,9%	97,4%	PO	91,3%	91,7%	92,0%
IC	92,0%	97,3%	95,3%	IC	89,3%	92,9%	93,2%
TC	97,4%	99,0%	99,0%	TC	90,5%	92,8%	91,8%
FF	95,5%	98,4%	97,2%	FF	91,0%	92,9%	93,6%
	EMD	EEMD	CEEMDAN		EMD	EEMD	CEEMDAN
(a)				(b)			
Sensibilidade				Sensibilidade (PCA)			
SD	93,9%	97,1%	97,8%	SD	78,5%	87,4%	78,0%
PO	94,8%	99,1%	90,6%	PO	81,0%	78,4%	81,0%
IC	69,5%	84,2%	81,6%	IC	79,0%	90,0%	83,9%
TC	93,5%	97,1%	98,5%	TC	80,0%	75,7%	85,0%
FF	92,9%	98,1%	98,4%	FF	82,1%	88,3%	80,3%
	EMD	EEMD	CEEMDAN		EMD	EEMD	CEEMDAN
(c)				(d)			
Especificidade				Especificidade (PCA)			
SD	98,2%	99,2%	98,2%	SD	97,3%	97,2%	97,4%
PO	94,2%	98,8%	98,8%	PO	94,5%	95,2%	95,7%
IC	97,8%	99,1%	98,6%	IC	92,3%	93,9%	94,6%
TC	98,3%	99,6%	99,1%	TC	93,3%	97,2%	94,0%
FF	96,2%	98,4%	96,7%	FF	93,7%	94,2%	95,4%
	EMD	EEMD	CEEMDAN		EMD	EEMD	CEEMDAN
(e)				(f)			
F1-score				F1-score (PCA)			
SD	93,6%	97,1%	95,7%	SD	83,3%	88,2%	83,0%
PO	88,9%	97,6%	92,5%	PO	81,6%	79,4%	83,1%
IC	73,9%	88,2%	85,0%	IC	76,4%	86,7%	86,0%
TC	93,0%	97,9%	97,82%	TC	78,1%	81,0%	84,0%
FF	91,0%	96,2%	95,04%	FF	80,4%	84,8%	82,3%
	EMD	EEMD	CEEMDAN		EMD	EEMD	CEEMDAN
(g)				(h)			

Fonte: Elaborada pelo autor.

A Figura 5.18 permite uma análise detalhada do desempenho do classificador considerando todos os subconjuntos (*folds*) para as diversas classes de defeito.

Figura 5.18. Variação da acurácia por classe, considerando todos os cinco *folds* com e sem PCA.

Fonte: Elaborada pelo autor.

É possível observar diferenças não só nos valores de acurácia entre os diversos métodos mas também na dispersão entre as diferentes classes, com destaque para a relativa alta dispersão no valor de acurácia na classe FF quando o algoritmo EMD é usado (Figura 5.18a), e para a variação desprezível para a classe FPTC quando o algoritmo CEEMDAN

é usado (Figura 5.18c).

Por outro lado, as matrizes de confusão e as curvas ROC são apresentadas na Tabela 5.5 e Figura 5.19, respectivamente. Para a Tabela 5.5, os valores são percentuais e representam os melhores resultados de classificação do conjunto de testes.

Tabela 5.5. Matrizes de confusão para a rede neural utilizada considerando os diversos defeitos e os três diferentes métodos de obtenção das IMFs EMD, EEMD e CEEMDAN.

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	92.5	0.0	2.8	6.1	0.0
PO	2.5	87.2	11.1	0.0	2.3
IC	0.0	2.1	94.4	0.0	2.3
TC	0.0	0.0	2.8	97.0	0.0
FF	2.5	0.0	0.0	0.0	97.7

(a) EMD

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	92.7	0.0	0.0	6.3	2.5
PO	4.9	69.6	9.8	18.8	5.0
IC	2.4	8.7	80.5	6.3	2.5
TC	0.0	6.5	2.4	81.3	5.0
FF	0.0	6.5	4.9	6.3	82.5

(b) EMD + PCA

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	100.0	0.0	0.0	0.0	0.0
PO	0.0	97.7	4.0	0.0	0.0
IC	2.4	4.7	88.0	0.0	0.0
TC	0.0	0.0	0.0	100.0	0.5
FF	0.0	0.0	4.0	0.0	97.6

(c) EEMD

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	89.5	11.5	0.0	2.7	0.0
PO	0.0	92.3	1.9	2.7	0.0
IC	2.6	19.2	82.7	8.1	0.0
TC	2.6	7.7	1.9	86.5	2.1
FF	5.3	15.4	1.9	0.0	85.1

(d) EEMD + PCA

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	94.6	0.0	0.0	5.3	0.0
PO	0.0	100.0	0.0	0.0	0.0
IC	2.7	6.3	92.7	0.0	0.0
TC	0.0	0.0	0.0	100.0	0.0
FF	2.7	0.0	0.0	0.0	98.1

(e) CEEMDAN

	Classe predita				
	SD	PO	IC	TC	FF
Classe real	SD	PO	IC	TC	FF
SD	90.6	4.4	0.0	0.0	3.0
PO	9.4	80.0	4.4	4.4	6.1
IC	9.4	4.4	88.9	0.0	0.0
TC	9.4	0.0	0.0	93.3	0.0
FF	3.1	8.9	0.0	0.0	84.8


(f) CEEMDAN + PCA

Fonte: Elaborada pelo autor.


É notável, através do valor da diagonal das matrizes de confusão que, em todos os cenários considerados, a classe predita é, de fato, a classe real para o modelo de rede neural usado. Quando os algoritmos de decomposição são associados à PCA, nota-se uma maior dispersão na matriz de confusão, indicando que se torna mais difícil, para o modelo de classificador utilizado, a diferenciação entre as diversas condições de interesse.

Por outro lado, as curvas ROC (Figura 5.19) mostram de maneira mais enfática que há uma degradação no desempenho quando a técnica PCA é utilizada, quando comparadas às curvas ROC onde a PCA não é utilizada.


Figura 5.19. Curva ROC de teste para os três métodos de decomposição sem PCA (esq.) e com PCA, considerando os melhores resultados.




(a) EMD




(c) EMD + PCA




(b) EEMD



(d) EEMD + PCA



(e) CEEMDAN



(f) CEEMDAN + PCA

Fonte: Elaborada pelo autor.

Observando-se as curvas acima, nota-se que algumas classes tiveram resultados melhores do que outras a depender do algoritmo de decomposição, mas vale lembrar que, como os gráficos representam os melhores resultados entre os *folds* e os vários valores de N_h , não é possível afirmar através deles que uma classe é melhor identificada por meio de um algoritmo ou outro. Em contrapartida, a análise conjunta dessas informações com as contidas na Tabela 5.4, que apresenta valores médios em relação a todos os *folds* para um mesmo N_h , e nos gráficos da Figura 5.18, pode-se afirmar que há indícios de que a classe “inclusão de escória” (IC) possua, de uma maneira geral, maior dificuldade em ser classificada corretamente, ainda que apresentando valores relativamente altos de acurácia.

5.5 Análise comparativa com trabalhos relacionados

Em (28), os autores apresentam um comparativo entre diversas técnicas de pré-processamento utilizando condições de interesse similares às deste trabalho, diferindo pela ausência do defeito “falta fusão” (FF).

A Tabela 5.6 mostra os valores das acurácias para cada condição de interesse. Os valores de desvio padrão relacionados às médias das acurácias para os métodos investigados neste trabalho foram suprimidos da referida tabela, para facilitar a comparação com o trabalho supramencionado, mas podem ser consultados na Tabela 5.3. Os resultados

obtidos através dos métodos examinados nesse trabalho foram destacados em negrito, em oposição aos demais resultados que foram retirados de (28).

Tabela 5.6. Comparação usando acurácias por cada condição de interesse e o produto de eficiências para diversos métodos de extração de características reportados na literatura e investigados nesse trabalho. Em negrito os valores obtidos neste trabalho.

Método	SD	PO	IC	FPTC	FF	PE
Nenhum (<i>A-scan</i>)	66,7	63,6	44,1	42,4	–	53,1
DFT	100,0	100,0	85,0	100,0	–	94,8
DFT + PCA	95,0	95,0	95,0	100,0	–	97,5
DCT	100,0	90,0	85,0	100,0	–	93,5
DCT + PCA	95,0	90,0	95,0	100,0	–	96,2
DWT	85,0	95,0	90,0	90,0	–	89,9
DWT + PCA	95,0	95,0	80,0	90,0	–	89,5
HHT – EMD	97,3	94,4	92,0	97,4	95,5	95,3
HHT – EMD + PCA	92,8	91,3	89,3	90,5	91,1	91,0
HHT – EEMD	98,8	98,9	97,3	99,0	98,4	98,5
HHT – EEMD + PCA	95,0	91,7	92,9	92,8	92,9	93,0
HHT – CEEMDAN	98,2	97,4	95,3	99,0	97,2	97,4
HHT – CEEMDAN + PCA	93,1	92,0	93,2	91,8	93,6	92,7

Fonte: Elaborada pelo autor.

Os resultados utilizando a THH com a PCA são levemente menores quando comparados as outras técnicas de pré-processamento também associadas à PCA. Por outro lado, enquanto a não utilização da PCA associada com a THH trouxe melhores resultados, no trabalho mencionado todas as técnicas tiveram melhoras. Frisa-se ainda que o trabalho cuja comparação é feita não menciona a utilização de validação cruzada.

CAPÍTULO 6

CONSIDERAÇÕES FINAIS

A utilização de estruturas soldadas compreende uma ampla gama de aplicações que envolvem desde ferramentas e utensílios domésticos até grandes estruturas como equipamentos industriais de grande porte, meios de transporte, tais como navios e aviões, e reservatórios para armazenamento de produtos químicos. Nestes últimos casos, devido à criticidade de suas aplicações, torna-se necessário garantir os requisitos mínimos necessários para o uso e operação sem riscos aos seus usuários e ao meio ambiente.

As denominadas inspeções ou ensaios não destrutivos oferecem, dentro de um vasto arsenal de possibilidades, ferramentas que permitem a avaliação da qualidade das estruturas manufaturadas, destacando-se, dentre as diversas opções, as inspeções baseadas em ultrassom, que de uma maneira geral fornecem uma boa acurácia nos resultados, facilidade de manuseio devido a portabilidade de equipamentos comercialmente disponíveis, bem como relativo baixo custo. Por outro lado, uma desvantagem existente é a necessidade de um operador devidamente qualificado e capacitado para a realização dos ensaios, bem como para compreensão e análise crítica dos resultados.

Nesse contexto, a criação de ferramentas de auxílio à análise da integridade e qualidade de estruturas tais como cordões de solda se faz oportuna. Este trabalho propôs, então, avaliar a utilização de técnicas de processamento de sinais que possibilitem a criação de um sistema inteligente para diagnóstico de discontinuidades em cordões de solda. Para tanto, um procedimento experimental foi realizado com duas chapas soldadas de aço carbono SAE 1020 por meio de três diferentes métodos de solda (MIG, TIG e eletrodo revestido), onde defeitos foram deliberadamente inseridos no cordão de solda, sendo eles: inclusão de escória (IC), porosidade (PO), falta de fusão (FF) e falta de penetração/trinca (FPTC), além de uma região com ausência de discontinuidades (SD). Utilizando-se a técnica de inspeção não destrutiva baseada em ultrassom conhecida como TOFD, foi possível obter os sinais de interesse para um posterior processamento e análise de suas características.

A proposta de utilizar a transformada de Hilbert-Huang surge devido a caracte-

rística dessa ferramenta em tratar adequadamente sinais não-lineares e não-estacionários, trazendo, portanto, indícios de se comportar como uma promissora ferramenta para extração de informações úteis para análise dos sinais observados empiricamente. Para que isso ocorra, os sinais de interesse devem ser decompostos em funções de modo intrínseco através do método de decomposição empírica em modos (EMD) e em seguida seus amplitudes e frequências instantâneas calculadas a partir da transformada de Hilbert (TH).

O EMD apresenta-se como um método heurístico que permite a obtenção dos modos de vibração do sinal em decomposição, no entanto, a sua implementação apresenta limitações, sendo a mais significativa denominada mixagem de modos, que ocorre devido a existência de modos de vibração de frequência próximas ou ainda devido a intermitências no sinal. Algumas adaptações e evoluções do método EMD foram propostas e ainda hoje há uma janela ampla de oportunidades de investigação de métodos mais robustos. Duas dessas evoluções merecem destaques pois permitem contornar a mixagem de modos, ao menos àquela relacionada com a proximidade entre frequências dos modos de vibração, são eles: o método de decomposição empírica em modos conjuntos (EEMD) e o método de decomposição empírica em modos conjuntos completos (CEEMD), sendo que este último possui uma adaptação, na qual os autores afirmam que possibilita a redução do custo computacional, sendo conhecida como decomposição empírica em modos conjuntos completos com ruído adaptativo (CEEMDAN).

A utilização dos diferentes métodos de decomposição citados anteriormente gera alterações nas funções de modo intrínseco e, potencialmente, no espectro de Hilbert dos sinais de interesse. De modo a avaliar a capacidade dessas ferramentas na extração de atributos dos sinais de interesse, um classificador baseado em rede neural artificial do tipo perceptron multicamadas foi projetado e diferentes parâmetros dos métodos de decomposição avaliados a partir da taxa de sucesso na classificação das descontinuidades no cordão de solda.

Os resultados deste trabalho foram previamente publicados (ver Apêndice [A](#)) considerando apenas o algoritmo EMD. Neste trabalho, em sua versão completa, outros dois algoritmos de decomposição foram considerados, além de melhorias como a implementação do método de validação cruzada.

Tais resultados continuaram mostrando o potencial da THH na extração de ca-

racterísticas em sinais de ultrassom obtidos com a técnica TOFD, alcançando valores de produto das eficiências superiores a 90% em todos os casos analisados, com destaque para a THH obtida a partir da EEMD (98,5%) e CEEMD (97,4%), ao passo que a EMD apresentou 95,3%, valores estes quando a técnica PCA não aplicada. Quando a redução dimensional foi considerada, apesar da leve redução no valor do produto das eficiências, ainda sim o classificador conseguiu discriminar as diferentes classes de defeito com eficiência de 91,0% pra THH-EMD, 93,0% para THH-EEMD e 92,7% para THH-CEEMDAN.

Apesar dos avanços existentes e das contribuições anualmente publicadas na literatura, vê-se ainda a necessidade de explorar diversas questões relacionadas a aplicação prática da EMD e de suas variantes. Condição de parada, métodos de interpolação e formas de mitigar os efeitos da mixagem de modos devido a intermitências no sinal ainda são assuntos que carecem de contribuições, o que pode ser um entrave para a aplicação apropriada dos métodos. Especialmente no caso dos métodos baseados em ruído assistido, como EEMD e CEEMDAN, a ausência de uma forma exata ou um guia para a determinação da amplitude do ruído gaussiano e o número de conjuntos (*ensembles*) leva a necessidade de experimentação excessiva através de tentativa e erro para a escolha dos melhores valores para que os parâmetros satisfaçam as condições necessárias para cada aplicação.

6.1 Sugestões de trabalhos futuros

Apesar dos resultados favoráveis à utilização da THH como uma ferramenta de pré-processamento capaz de realizar a extração adequada de características para as diversas condições de defeito analisadas nesse trabalho, há alguns aspectos que devem ser melhor compreendidos para potencializar o seu uso e permitir, futuramente, a sua utilização em sistemas embarcados, garantindo uma das vantagens que as técnicas de inspeção baseadas em ultrassom exibem, que é a sua portabilidade.

Nesse sentido, para o caso da utilização do EMD como método de decomposição, há de se averiguar o impacto no desempenho do algoritmo quando outras formas de interpolação são utilizadas, bem como o impacto no número de IMFs geradas para outras condições de parada, inclusive com valores diferentes dos usualmente mencionados na literatura. Por outro lado, no caso dos algoritmos que evoluíram a partir do EMD (EEMD

e CEEMD e suas variantes), é notável a necessidade de obter-se uma maneira exata de relacionar os parâmetros w_n e N_{ens} , sem a necessidade de testes exaustivos.

A redução dimensional das características de frequência instantânea obtidas a partir da aplicação da transformada de Hilbert sobre as IMFs também pode e deve ser explorada, uma vez que podem conter informações relevantes com potencial de melhorar a acurácia dos sistemas classificatórios. Além do mais, tal redução torna-se crucial quando se considera a implementação da THH em sistemas microprocessados.

Além disso, novas arquiteturas de classificação podem ser examinadas, o que inclui, por exemplo, redes neurais profundas, sendo necessário, no entanto, um esforço adicional na obtenção de um conjunto maior de realizações, ou ainda a proposição de uma estratégia eficiente de *data augmentation*.

REFERÊNCIAS

- [1] HUANG, Norden E. *Introduction to the Hilbert-Huang transform and its related mathematical problems*, chapter 1, pages 1–26.
- [2] CARL, Zweben. *Composite Materials*, chapter 10, pages 1–37. American Cancer Society, 2015.
- [3] GHOLIZADEH, S. A review of non-destructive testing methods of composite materials. *Procedia Structural Integrity*, 1:50 – 57, 2016. XV Portuguese Conference on Fracture, PCF 2016, 10-12 February 2016, Paco de Arcos, Portugal.
- [4] LOCKARD, C. D. *Anomaly detection in radiographic images of composite materials via crosshatch regression*. PhD thesis, Mills College, 2015.
- [5] HOU, Wenhui; ZHANG, Dashan; WEI, Ye; GUO, Jie; ZHANG, Xiaolong. Review on computer aided weld defect detection from radiography images. *Applied Sciences*, 10(5):1878, Mar 2020.
- [6] DONG, Shaohua; SUN, Xuan; XIE, Shuyi; WANG, Mingfeng. Automatic defect identification technology of digital image of pipeline weld. *Natural Gas Industry B*, 6(4):399 – 403, 2019.
- [7] CARVALHO, A. A; SUITA, R. C. S. B.; SILVA, R. R.; REBELLO, J. M. A. Evaluation of the relevant features of welding defects in radiographic inspection. *Materials Research*, 6:427 – 432, 06 2003.
- [8] Top 11 advantages of ultrasonic testing. Zetec, Inc. Disponível em: <<https://www.zetec.com/blog/top-11-advantages-of-ultrasonic-testing/>>, . Acesso em 12 de maio de 2020.
- [9] OLIVEIRA, M. A.; FARIAS, C.; SILVA, I.; SANTOS, Y.; SIMAS FILHO, E. Identificação de danos em pás de turbinas eólicas utilizando classificação automática através de detecção de novidades. *Conferência de Tecnologia de Equipamentos para Indústria 2017*.
- [10] What are the advantages and disadvantages of ultrasonic examination in non-destructive examination (NDE)?. TWI ltd. Disponível em: <<https://www.twi-global.com/technical-knowledge/faqs/faq-what-are-the-advantages-and-disadvantages-of-ultrasonic-examination-in-non-destructive-examination-nde>>, . Acesso em 22 de abril de 2020.
- [11] Ultrasonic testing: Advantages & disadvantages. Texas Non-destructive Testing Academy. Disponível em: <<https://www.txndt.com/safety-section/ultrasonic-testing>>, . Acesso em 25 de abril de 2020.

- [12] SIMAS FILHO, E. F.; SILVA, M. M.; FARIAS, P. C. M. A.; ALBUQUERQUE, M. C. S.; SILVA, I. C.; FARIAS, C. T. T. Flexible decision support system for ultrasound evaluation of fiber-metal laminates implemented in a dsp. *NDT E International*, 79:38 – 45, 2016.
- [13] OLIVEIRA, M. A.; SIMAS FILHO, E. F.; SILVA, I. C.; ALBUQUERQUE, M. C. S.; FARIAS, C. T. T.; SILVA, L. C. Detecção de novidades na classificação de defeitos em junta soldada de aço SAE1020. *Congresso Nacional de Ensaaios Não Destrutivos e Inspeção (ConaEND)*, 2016. Anais do CONAEND.
- [14] HUANG, Norden E.; SHEN, Zheng; LONG, Steven R.; WU, Manli C.; SHIH, Hsing H.; ZHENG, Quanan; YEN, Nai-Chyuan; TUNG, Chi Chao; LIU, Henry H. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 454(1971):903–995, 1998.
- [15] SOLODOV, Igor; DÖRING, Daniel; BUSSE, Gerd. New opportunities for ndt using non-linear interaction of elastic waves with defects. *Strojniški vestnik - Journal of Mechanical Engineering*, 57(3):169–182, 2011.
- [16] Standard Guide for Testing Performance of Amusement Rides and Devices (Withdrawn 2013). Standard, ASTM International, West Conshohocken, PA, 2009.
- [17] International Atomic Energy Agency. IAEA-TCS–9 non-destructive testing: A guidebook for industrial management and quality control personnel, 1999.
- [18] AHMAD, Aquil; BOND, Leonard J. *Nondestructive Evaluation of Materials*. ASM International, Ohio, USA, 2018.
- [19] MATHERS, Gene. Ultrasonic examination - part 1. TWI Ltd. Disponível em: <<https://www.twi-global.com/technical-knowledge/job-knowledge/ultrasonic-examination-part-1-127>>, . Acesso em 22 de abril de 2020.
- [20] Angle beam testing. NDT Resource Center. Disponível em: <<https://www.nde-ed.org/EducationResources/HighSchool/Sound/anglebeam.htm>>, . Acesso em 25 de abril de 2020.
- [21] SINGH, Ramesh. In *Applied Welding Engineering*, page v. Butterworth-Heinemann, Boston, 2012.
- [22] Welding and allied processes — Classification of geometric imperfections in metallic materials — Part 1: Fusion welding. Standard, International Organization for Standardization, Geneva, CHE, 2007.
- [23] VAN DEN ABEELE, K.E. A; JOHNSON, P. A.; SUTIN, A. Nonlinear elastic wave spectroscopy (news) techniques to discern material damage, part i: Nonlinear wave modulation spectroscopy (nwms). *Research in Nondestructive Evaluation*, 12(1):17–30, 2000.
- [24] PIECZONKA, Lukasz; KLEPKA, Andrzej; MARTOWICZ, Adam; STASZEWSKI, Wieslaw J. Nonlinear vibroacoustic wave modulations for structural damage detection: an overview. *Optical Engineering*, 55(1):1 – 9, 2015.

- [25] HALLER, Kristian. Nonlinear acoustics applied to nondestructive testing. Number 7 in Blekinge Institute of Technology Licentiate Dissertation Series, page 97. Blekinge Institute of Technology, 2007.
- [26] GUYON, Isabelle; GUNN, Steve; NICKRAVESH, Masoud; ZADEH, Lotfi A. *Feature Extraction: Foundations and Applications (Studies in Fuzziness and Soft Computing)*. Springer-Verlag, Berlin, Heidelberg, 2006.
- [27] R.F. Hoskins. Chapter 6 - fourier series and transforms. In R.F. Hoskins, editor, *Delta Functions (Second Edition)*, pages 128 – 153. Woodhead Publishing, second edition edition, 2011.
- [28] CRUZ, F. C.; SIMAS FILHO, E. F.; ALBUQUERQUE, M. C. S.; SILVA, I. C.; FARIAS, C. T. T.; GOUVÊA, L. L. Efficient feature selection for neural network based detection of flaws in steel welded joints using ultrasound testing. *Ultrasonics*, 73:1 – 8, 2017.
- [29] HUANG, Norden E.; ZHAOHUA, Wu. A review on hilbert-huang transform: Method and its applications to geophysical studies. *Reviews of Geophysics*, 46(2).
- [30] HUANG, Norden E.; SHEN, Zheng; LONG, Steven R. A new view of nonlinear water waves: The hilbert spectrum. *Annual Review of Fluid Mechanics*, 31(1):417–457, 1999.
- [31] STORK, Milan. Hilbert-Huang Transform and Its Applications in Engineering and Biomedical Signal Analysis. In RECENT RESEARCHES in CIRCUITS and SYSTEMS, pages 188–195. WSEAS Press, 2012.
- [32] HUANG, Norden E.; WU, Man-Li C.; LONG, Steven R.; SHEN, Samuel S. P.; QU, Wendong; GLOERSEN, Per; FAN, Kuang L. A confidence limit for the empirical mode decomposition and hilbert spectral analysis. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 459(2037):2317–2345, 2003.
- [33] FOSSO, O. B.; MOLINAS, M. Emd mode mixing separation of signals with close spectral proximity in smart grids. In *2018 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*, pages 1–6, 2018.
- [34] WU, Zhaohua; HUANG, Norden E. Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 01(01):1–41, 2009.
- [35] LI, Meijiao; WANG, Huaqing; TANG, Gang; YUAN, Hongfang; YANG, Yang. An improved method based on ceemd for fault diagnosis of rolling bearing. *Advances in Mechanical Engineering*, 6:676205, 2014.
- [36] TORRES, M. E.; COLOMINAS, M. A.; SCHLOTTHAUER, G.; FLANDRIN, P. A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 4144–4147, 2011.

- [37] COLOMINAS, Marcelo A.; SCHLOTTHAUER, Gastón; TORRES, María E. Improved complete ensemble emd: A suitable tool for biomedical signal processing. *Biomedical Signal Processing and Control*, 14:19 – 29, 2014.
- [38] ÖZDEMİR, N.; YILDIRIM, E. Epileptic seizure prediction based on hilbert huang transform and artificial neural networks. In *2012 20th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4, 2012.
- [39] WICKRAMASURIYA, D. S.; WIJESINGHE, L. P.; MALLAWAARACHCHI, S. Seizure prediction using hilbert huang transform on field programmable gate array. In *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pages 933–937, 2015.
- [40] DEEPIKA, G.; RAO, K. S. Fpga implementation of huang-hilber transform for classification of epileptic seizures using artifitial neural network. 2019.
- [41] RODRÍGUEZ, R.; BILA, J.; MEXICANO, A.; CERVANTES, S.; PONCE, R.; NGHIEN, N. B. Hilbert-huang transform and neural networks for electrocardiogram modeling and prediction. In *2014 10th International Conference on Natural Computation (ICNC)*, pages 561–567, 2014.
- [42] NEZHEVENKO, E. S.; FEOKTISTOV, A. S.; DASHEVSKII, O. Yu. Neural network classification of hyperspectral images on the basis of the Hilbert-Huang transform. *Optoelectronics, Instrumentation and Data Processing*, 53(2):165–170, March 2017.
- [43] CHENG, Junsheng; YU, Dejie; YANG, Yu. Application of support vector regression machines to the processing of end effects of hilbert–huang transform. *Mechanical Systems and Signal Processing*, 21(3):1197 – 1211, 2007.
- [44] LEI, Yaguo; HE, Zhengjia; ZI, Yanyang. Application of the eemd method to rotor fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 23(4):1327 – 1338, 2009.
- [45] LEISK, G.; MILLER, E.; MURPHY, D. Improving ultrasonic c-scan resolution using the hilbert-huang transform. *AIP Conference Proceedings*, 760, 04 2005.
- [46] KAZYS, R.; TUMSYS, O.; PAGODINAS, D. Ultrasonic detection of defects in strongly attenuating structures using the hilbert–huang transform. *NDT E International*, 41(6):457 – 466, 2008.
- [47] GAO, Chengqiang; CHEN, Guiming; SHI, Xiaomei. Application of hilbert-huang transform in ultrasonic echo signal processing of composites. *Journal of Physics: Conference Series*, 1325:012168, 10 2019.
- [48] LU, Yufeng; ORUKLU, Erdal; SANIIE, Jafar. Application of hilbert-huang transform for ultrasonic nondestructive evaluation. pages 1499 – 1502, 12 2008.
- [49] JOLLIFFE, Ian T.; CADIMA, Jorge. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065):20150202, 2016.

- [50] RASAMOELINA, A. D.; ADJAILIA, F.; SINCAK, P. A review of activation function for artificial neural network. In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMi)*, pages 281–286, 2020.
- [51] NWANKPA, Chigozie; IJOMAH, Winifred; GACHAGAN, Anthony; MARSHALL, Stephen. Activation functions: Comparison of trends in practice and research for deep learning. 11 2018.
- [52] MOLLER, Martin Fodslette. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4):525 – 533, 1993.
- [53] JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. *An Introduction to Statistical Learning: with Applications in R*. Springer, 2013.
- [54] Ultrasonic Transducers - Wedges, cables, test blocks. Folha de dados, Panametrics, USA, 2016.
- [55] Olympus Panametrics Model 5077PR. Folha de dados, Olympus Panametrics, USA, 2014.
- [56] Oscilloscope Tektronix TDS-2024B. Folha de dados, Tektronix, USA, 2009.
- [57] British-Standard-Institution. Part 2: Determination of density and porosity. *Advanced technical ceramics. Monolithic ceramics. General and textural properties.*, pages 1–16, 1993.
- [58] Api 653 - tank inspection, repair, alteration and reconstruction. Norma, American Petroleum Institute, USA, 2001.
- [59] Api 650 - welded tanks for oil storage. Norma, American Petroleum Institute, USA, 2007.
- [60] WU, Zhaohua; HUANG, Norden E. Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 01(01):1–41, 2009.
- [61] LEI, Yaguo; HE, Zhengjia; ZI, Yanyang. Application of the eemd method to rotor fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 23(4):1327 – 1338, 2009.
- [62] DE GOEJE, M. P.; WAPENAAR, K. E. D. Non-destructive inspection of carbon fibre-reinforced plastics using eddy current methods. *Composites*, 23(3):147 – 157, 1992.
- [63] MIAO, Jianyu; NIU, Lingfeng. A survey on feature selection. *Procedia Computer Science*, 91:919 – 926, 2016. Promoting Business Analytics and Quantitative Management of Technology: 4th International Conference on Information Technology and Quantitative Management (ITQM 2016).
- [64] MOHAMED, Muhammad ‘Arif; HASSAN, Haswadi; NASIEN, Dewi; HARON, Habbillah. A review on feature extraction and feature selection for handwritten character recognition. *International Journal of Advanced Computer Science and Applications*, 6(2), 2015.

- [65] KHALID, S.; KHALIL, T.; NASREEN, S. A survey of feature selection and feature extraction techniques in machine learning. In *2014 Science and Information Conference*, pages 372–378, Aug 2014.
- [66] CHANDRASHEKAR, Girish; SAHIN, Ferat. A survey on feature selection methods. *Computers Electrical Engineering*, 40(1):16 – 28, 2014. 40th-year commemorative issue.

PUBLICAÇÕES

A.1 XIV Congresso Brasileiro de Inteligência Computacional (CBIC 2019)

Título: Aplicação da Transformada de Hilbert-Huang em um Sistema Inteligente de Classificação de Sinais de Ensaios Não Destrutivos por Ultrassom

Autores: Franklin Lima Santos, Paulo César M. A. Farias, Eduardo F. de Simas Filho, Maria Cléa S. Albuquerque, Ivan C. Silva, Claudia T. T. Farias

Resumo: A utilização de técnicas de processamento de sinais como auxílio no diagnóstico de falhas em processos de manufatura tem sido bastante promissora, pois permite o aumento da eficiência dos processos, assegura qualidade aos produtos e a segurança das instalações. Este trabalho propõe a utilização da transformada de Hilbert-Huang (HHT) como ferramenta de extração de características dos sinais de ultrassom obtidos em ensaio experimental. A HHT é uma decomposição tempo-frequência que utiliza funções base de transformação estimadas a partir dos sinais de interesse. Um classificador baseado em rede neural artificial tipo perceptron de múltiplas camadas apresentou 97,4% de acurácia, quando usando como entradas atributos oriundos da HHT. Esse resultado se mostrou superior aos obtidos em trabalhos anteriores com outras técnicas de pré-processamento, cujo maior valor obtido foi utilizando a DFT (94,8%).

Palavras-chave: Transformada de Hilbert-Huang, processamento de sinais, ultrassom, ensaios não destrutivos, redes neurais.

Páginas: 8

Código DOI: 10.21528/CBIC2019-126

ANEXO A

IMPLEMENTAÇÃO DOS MÉTODOS EMD, EEMD E CEEMDAN

A.1 Algoritmo EMD

```
1 %EMD computes Empirical Mode Decomposition
2 %
3 %
4 % Syntax
5 %
6 %
7 % IMF = EMD(X)
8 % IMF = EMD(X,...,'Option_name',Option_value,...)
9 % IMF = EMD(X,OPTS)
10 % [IMF,ORT,NB_ITERATIONS] = EMD(...)
11 %
12 %
13 % Description
14 %
15 %
16 % IMF = EMD(X) where X is a real vector computes the Empirical Mode
17 % Decomposition [1] of X, resulting in a matrix IMF containing 1 IMF per row, the
18 % last one being the residue. The default stopping criterion is the one proposed
19 % in [2]:
20 %
21 % at each point, mean_amplitude < THRESHOLD2*envelope_amplitude
22 % &
23 % mean of boolean array {(mean_amplitude)/(envelope_amplitude) > THRESHOLD} < TOLERANCE
24 % &
25 % |#zeros-#extrema|<=1
26 %
27 % where mean_amplitude = abs(envelope_max+envelope_min)/2
28 % and envelope_amplitude = abs(envelope_max-envelope_min)/2
29 %
30 % IMF = EMD(X) where X is a complex vector computes Bivariate Empirical Mode
31 % Decomposition [3] of X, resulting in a matrix IMF containing 1 IMF per row, the
32 % last one being the residue. The default stopping criterion is similar to the
33 % one proposed in [2]:
34 %
35 % at each point, mean_amplitude < THRESHOLD2*envelope_amplitude
36 % &
37 % mean of boolean array {(mean_amplitude)/(envelope_amplitude) > THRESHOLD} < TOLERANCE
38 %
39 % where mean_amplitude and envelope_amplitude have definitions similar to the
40 % real case
41 %
42 % IMF = EMD(X,...,'Option_name',Option_value,...) sets options Option_name to
43 % the specified Option_value (see Options)
44 %
45 % IMF = EMD(X,OPTS) is equivalent to the above syntax provided OPTS is a struct
46 % object with field names corresponding to option names and field values being the
47 % associated values
48 %
49 % [IMF,ORT,NB_ITERATIONS] = EMD(...) returns an index of orthogonality
50 %
51 %      _ |IMF(i,:).*IMF(j,:)|
52 % ORT = \ -----
53 %      /
54 %      || X ||^2
55 % i~=j
56 %
57 % and the number of iterations to extract each mode in NB_ITERATIONS
```

```

58 %
59 %
60 % Options
61 %
62 %
63 % stopping criterion options:
64 %
65 % STOP: vector of stopping parameters [THRESHOLD,THRESHOLD2,TOLERANCE]
66 % if the input vector's length is less than 3, only the first parameters are
67 % set, the remaining ones taking default values.
68 % default: [0.05,0.5,0.05]
69 %
70 % FIX (int): disable the default stopping criterion and do exactly <FIX>
71 % number of sifting iterations for each mode
72 %
73 % FIX_H (int): disable the default stopping criterion and do <FIX_H> sifting
74 % iterations with |#zeros-#extrema|<=1 to stop [4]
75 %
76 % bivariate/complex EMD options:
77 %
78 % COMPLEX_VERSION: selects the algorithm used for complex EMD ([3])
79 % COMPLEX_VERSION = 1: "algorithm 1"
80 % COMPLEX_VERSION = 2: "algorithm 2" (default)
81 %
82 % NDIRS: number of directions in which envelopes are computed (default 4)
83 % rem: the actual number of directions (according to [3]) is 2*NDIRS
84 %
85 % other options:
86 %
87 % T: sampling times (line vector) (default: 1:length(x))
88 %
89 % MAXITERATIONS: maximum number of sifting iterations for the computation of each
90 % mode (default: 2000)
91 %
92 % MAXMODES: maximum number of imfs extracted (default: Inf)
93 %
94 % DISPLAY: if equals to 1 shows sifting steps with pause
95 % if equals to 2 shows sifting steps without pause (movie style)
96 % rem: display is disabled when the input is complex
97 %
98 % INTERP: interpolation scheme: 'linear', 'cubic', 'pchip' or 'spline' (default)
99 % see interp1 documentation for details
100 %
101 % MASK: masking signal used to improve the decomposition according to [5]
102 %
103 %
104 % Examples
105 %
106 %
107 %X = rand(1,512);
108 %
109 %IMF = emd(X);
110 %
111 %IMF = emd(X,'STOP',[0.1,0.5,0.05],'MAXITERATIONS',100);
112 %
113 %T=linspace(0,20,1e3);
114 %X = 2*exp(i*T)+exp(3*i*T)+.5*T;
115 %IMF = emd(X,'T',T);
116 %
117 %OPTIONS.DISPLAY = 1;
118 %OPTIONS.FIX = 10;
119 %OPTIONS.MAXMODES = 3;
120 %[IMF,ORT,NBITS] = emd(X,OPTIONS);
121 %
122 %
123 % References
124 %
125 %
126 % [1] N. E. Huang et al., "The empirical mode decomposition and the
127 % Hilbert spectrum for non-linear and non stationary time series analysis",
128 % Proc. Royal Soc. London A, Vol. 454, pp. 903-995, 1998
129 %
130 % [2] G. Rilling, P. Flandrin and P. Goncalves

```

```

131 % "On Empirical Mode Decomposition and its algorithms",
132 % IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing
133 % NSIP-03, Grado (I), June 2003
134 %
135 % [3] G. Rilling, P. Flandrin, P. Goncalves and J. M. Lilly.,
136 % "Bivariate Empirical Mode Decomposition",
137 % Signal Processing Letters (submitted)
138 %
139 % [4] N. E. Huang et al., "A confidence limit for the Empirical Mode
140 % Decomposition and Hilbert spectral analysis",
141 % Proc. Royal Soc. London A, Vol. 459, pp. 2317-2345, 2003
142 %
143 % [5] R. Deering and J. F. Kaiser, "The use of a masking signal to improve
144 % empirical mode decomposition", ICASSP 2005
145 %
146 %
147 % See also
148 % emd_visu (visualization),
149 % emdc, emdc_fix (fast implementations of EMD),
150 % cemdc, cemdc_fix, cemdc2, cemdc2_fix (fast implementations of bivariate EMD),
151 % hhspectrum (Hilbert-Huang spectrum)
152 %
153 %
154 % G. Rilling, last modification: 3.2007
155 % gabriel.rilling@ens-lyon.fr
156
157
158 function [imf,ort,nbits] = emd(varargin)
159
160 [x,t,sd,sd2,tol,MODE_COMPLEX,ndirs,display_sifting,sdt,sd2t,r,imf,
161 k,nbit,NbIt,MAXITERATIONS,FIXE,FIXE_H,MAXMODES,INTERP,mask] = init(varargin{:});
162
163 if display_sifting
164     fig_h = figure;
165 end
166
167
168 %main loop : requires at least 3 extrema to proceed
169 while (~stop_EMD(r,MODE_COMPLEX,ndirs) && (k < MAXMODES+1 || MAXMODES == 0) && ~any(mask))
170
171     % current mode
172     m = r;
173
174     % mode at previous iteration
175     mp = m;
176
177     %computation of mean and stopping criterion
178     if FIXE
179         [stop_sift,moyenne] = stop_sifting_fixe(t,m,INTERP,MODE_COMPLEX,ndirs);
180     elseif FIXE_H
181         stop_count = 0;
182         [stop_sift,moyenne] = stop_sifting_fixe_h(t,m,INTERP,stop_count,FIXE_H,MODE_COMPLEX,ndirs);
183     else
184         [stop_sift,moyenne] = stop_sifting(m,t,sd,sd2,tol,INTERP,MODE_COMPLEX,ndirs);
185     end
186
187     % in case the current mode is so small that machine precision can cause
188     % spurious extrema to appear
189     if (max(abs(m))) < (1e-10)*(max(abs(x)))
190         if ~stop_sift
191             warning('emd:warning','forced stop of EMD : too small amplitude')
192         else
193             disp('forced stop of EMD : too small amplitude')
194         end
195         break
196     end
197
198
199 % sifting loop
200 while ~stop_sift && nbit<MAXITERATIONS
201     if (~MODE_COMPLEX && nbit>MAXITERATIONS/5 && mod(nbit,floor(MAXITERATIONS/10))==0 && ~FIXE && nbit >
202         100)
203         disp(['mode ',int2str(k),', iteration ',int2str(nbit)])

```

```

203     if exist('s','var')
204         disp(['stop parameter mean value : ',num2str(s)])
205     end
206     [im,iM] = extr(m);
207     disp(['int2str(sum(m(im) > 0)), ' minima > 0; ',int2str(sum(m(iM) < 0)), ' maxima < 0.'])
208 end
209
210 %sifting
211 m = m - moyenne;
212
213 %computation of mean and stopping criterion
214 if FIXE
215     [stop_sift,moyenne] = stop_sifting_fixe(t,m,INTERP,MODE_COMPLEX,ndirs);
216 elseif FIXE_H
217     [stop_sift,moyenne,stop_count] =
218         stop_sifting_fixe_h(t,m,INTERP,stop_count,FIXE_H,MODE_COMPLEX,ndirs);
219 else
220     [stop_sift,moyenne,s] = stop_sifting(m,t,sd,sd2,tol,INTERP,MODE_COMPLEX,ndirs);
221 end
222
223 % display
224 if display_sifting && ~MODE_COMPLEX
225     NBSYM = 2;
226     [indmin,indmax] = extr(mp);
227     [tmin,tmax,mmin,mmax] = boundary_conditions(indmin,indmax,t,mp,mp,NBSYM);
228     envminp = interp1(tmin,mmin,t,INTERP);
229     envmaxp = interp1(tmax,mmax,t,INTERP);
230     envmoyp = (envminp+envmaxp)/2;
231     if FIXE || FIXE_H
232         display_end_fixe(t,m,mp,r,envminp,envmaxp,envmoyp,nbit,k,display_sifting)
233     else
234         exp=2*(abs(envmoyp))./(abs(envmaxp-envminp));
235         sp = mean(exp);
236         display_end(t,m,mp,r,envminp,envmaxp,envmoyp,s,sp,exp,sdt,sd2t,nbit,k,display_sifting,stop_sift)
237     end
238 end
239
240 mp = m;
241 nbit=nbit+1;
242 NbIt=NbIt+1;
243
244 if(nbit==(MAXITERATIONS-1) && ~FIXE && nbit > 100)
245     if exist('s','var')
246         warning('emd:warning',['forced stop of sifting : too many iterations... mode ',int2str(k),'. stop
247             parameter mean value : ',num2str(s)])
248     else
249         warning('emd:warning',['forced stop of sifting : too many iterations... mode ',int2str(k),'.'])
250     end
251 end
252
253 end % sifting loop
254 imf(k,:) = m;
255 if display_sifting
256     disp(['mode ',int2str(k), ' stored'])
257 end
258 nbits(k) = nbit;
259 k = k+1;
260
261 r = r - m;
262 nbit=0;
263
264 end %main loop
265
266 if any(r) && ~any(mask)
267     imf(k,:) = r;
268 end
269
270 ort = io(x,imf);
271
272 if display_sifting
273     close

```

```

274 end
275 end
276
277 %-----
278 % tests if there are enough (3) extrema to continue the decomposition
279 function stop = stop_EMD(r,MODE_COMPLEX,ndirs)
280 if MODE_COMPLEX
281     for k = 1:ndirs
282         phi = (k-1)*pi/ndirs;
283         [indmin,indmax] = extr(real(exp(i*phi)*r));
284         ner(k) = length(indmin) + length(indmax);
285     end
286     stop = any(ner < 3);
287 else
288     [indmin,indmax] = extr(r);
289     ner = length(indmin) + length(indmax);
290     stop = ner < 3;
291 end
292 end
293
294 %-----
295 % computes the mean of the envelopes and the mode amplitude estimate
296 function [envmoy,nem,nzm,amp] = mean_and_amplitude(m,t,INTERP,MODE_COMPLEX,ndirs)
297 NBSYM = 2;
298 if MODE_COMPLEX
299     switch MODE_COMPLEX
300     case 1
301         for k = 1:ndirs
302             phi = (k-1)*pi/ndirs;
303             y = real(exp(-i*phi)*m);
304             [indmin,indmax,indzer] = extr(y);
305             nem(k) = length(indmin)+length(indmax);
306             nzm(k) = length(indzer);
307             [tmin,tmax,zmin,zmax] = boundary_conditions(indmin,indmax,t,y,m,NBSYM);
308             envmin(k,:) = interp1(tmin,zmin,t,INTERP);
309             envmax(k,:) = interp1(tmax,zmax,t,INTERP);
310         end
311         envmoy = mean((envmin+envmax)/2,1);
312         if nargout > 3
313             amp = mean(abs(envmax-envmin),1)/2;
314         end
315     case 2
316         for k = 1:ndirs
317             phi = (k-1)*pi/ndirs;
318             y = real(exp(-i*phi)*m);
319             [indmin,indmax,indzer] = extr(y);
320             nem(k) = length(indmin)+length(indmax);
321             nzm(k) = length(indzer);
322             [tmin,tmax,zmin,zmax] = boundary_conditions(indmin,indmax,t,y,y,NBSYM);
323             envmin(k,:) = exp(i*phi)*interp1(tmin,zmin,t,INTERP);
324             envmax(k,:) = exp(i*phi)*interp1(tmax,zmax,t,INTERP);
325         end
326         envmoy = mean((envmin+envmax),1);
327         if nargout > 3
328             amp = mean(abs(envmax-envmin),1)/2;
329         end
330     end
331 else
332     [indmin,indmax,indzer] = extr(m);
333     nem = length(indmin)+length(indmax);
334     nzm = length(indzer);
335     [tmin,tmax,mmin,mmax] = boundary_conditions(indmin,indmax,t,m,m,NBSYM);
336     envmin = interp1(tmin,mmin,t,INTERP);
337     envmax = interp1(tmax,mmax,t,INTERP);
338     envmoy = (envmin+envmax)/2;
339     if nargout > 3
340         amp = mean(abs(envmax-envmin),1)/2;
341     end
342 end
343 end
344
345 %-----
346 % default stopping criterion

```

```

347 function [stop,envmoy,s] = stop_sifting(m,t,sd,sd2,tol,INTERP,MODE_COMPLEX,ndirs)
348 try
349     [envmoy,nem,nzm,amp] = mean_and_amplitude(m,t,INTERP,MODE_COMPLEX,ndirs);
350     sx = abs(envmoy)./amp;
351     s = mean(sx);
352     stop = ~((mean(sx > sd) > tol | any(sx > sd2)) & (all(nem > 2)));
353     if ~MODE_COMPLEX
354         stop = stop && ~(abs(nzm-nem)>1);
355     end
356 catch
357     stop = 1;
358     envmoy = zeros(1,length(m));
359     s = NaN;
360 end
361 end
362
363 %-----
364 % stopping criterion corresponding to option FIX
365 function [stop,moyenne]= stop_sifting_fixe(t,m,INTERP,MODE_COMPLEX,ndirs)
366 try
367     moyenne = mean_and_amplitude(m,t,INTERP,MODE_COMPLEX,ndirs);
368     stop = 0;
369 catch
370     moyenne = zeros(1,length(m));
371     stop = 1;
372 end
373 end
374
375 %-----
376 % stopping criterion corresponding to option FIX_H
377 function [stop,moyenne,stop_count]= stop_sifting_fixe_h(t,m,INTERP,stop_count,FIXE_H,MODE_COMPLEX,ndirs)
378 try
379     [moyenne,nem,nzm] = mean_and_amplitude(m,t,INTERP,MODE_COMPLEX,ndirs);
380     if (all(abs(nzm-nem)>1))
381         stop = 0;
382         stop_count = 0;
383     else
384         stop_count = stop_count+1;
385         stop = (stop_count == FIXE_H);
386     end
387 catch
388     moyenne = zeros(1,length(m));
389     stop = 1;
390 end
391 end
392
393 %-----
394 % displays the progression of the decomposition with the default stopping criterion
395 function display_emd(t,m,mp,r,envmin,envmax,envmoy,s,sb,sx,sdt,sd2t,nbit,k,display_sifting,stop_sift)
396 subplot(4,1,1)
397 plot(t,mp);hold on;
398 plot(t,envmax,'--k');plot(t,envmin,'--k');plot(t,envmoy,'r');
399 title(['IMF ',int2str(k),'; iteration ',int2str(nbit),' before sifting']);
400 set(gca,'XTick',[])
401 hold off
402 subplot(4,1,2)
403 plot(t,sx)
404 hold on
405 plot(t,sdt,'--r')
406 plot(t,sd2t,':k')
407 title('stop parameter')
408 set(gca,'XTick',[])
409 hold off
410 subplot(4,1,3)
411 plot(t,m)
412 title(['IMF ',int2str(k),'; iteration ',int2str(nbit),' after sifting']);
413 set(gca,'XTick',[])
414 subplot(4,1,4);
415 plot(t,r-m)
416 title('residue');
417 disp(['stop parameter mean value : ',num2str(sb),' before sifting and ',num2str(s),' after'])
418 if stop_sift
419     disp('last iteration for this mode')

```

```

420 end
421 if display_sifting == 2
422     pause(0.01)
423 else
424     pause
425 end
426 end
427
428 %-----
429 % displays the progression of the decomposition with the FIX and FIX_H stopping criteria
430 function display_emd_fixe(t,m,mp,r,envmin,envmax,envmoy,nbit,k,display_sifting)
431 subplot(3,1,1)
432 plot(t,mp);hold on;
433 plot(t,envmax,'--k');plot(t,envmin,'--k');plot(t,envmoy,'r');
434 title(['IMF ',int2str(k),'; iteration ',int2str(nbit),' before sifting']);
435 set(gca,'XTick',[])
436 hold off
437 subplot(3,1,2)
438 plot(t,m)
439 title(['IMF ',int2str(k),'; iteration ',int2str(nbit),' after sifting']);
440 set(gca,'XTick',[])
441 subplot(3,1,3);
442 plot(t,r-m)
443 title('residue');
444 if display_sifting == 2
445     pause(0.01)
446 else
447     pause
448 end
449 end
450
451 %-----
452 % defines new extrema points to extend the interpolations at the edges of the
453 % signal (mainly mirror symmetry)
454 function [tmin,tmax,zmin,zmax] = boundary_conditions(indmin,indmax,t,x,z,nbsym)
455
456 lx = length(x);
457
458 if (length(indmin) + length(indmax) < 3)
459     error('not enough extrema')
460 end
461
462 % boundary conditions for interpolations :
463
464 if indmax(1) < indmin(1)
465     if x(1) > x(indmin(1))
466         lmax = fliplr(indmax(2:min(end,nbsym+1)));
467         lmin = fliplr(indmin(1:min(end,nbsym)));
468         lsym = indmax(1);
469     else
470         lmax = fliplr(indmax(1:min(end,nbsym)));
471         lmin = [fliplr(indmin(1:min(end,nbsym-1))),1];
472         lsym = 1;
473     end
474 else
475
476     if x(1) < x(indmax(1))
477         lmax = fliplr(indmax(1:min(end,nbsym)));
478         lmin = fliplr(indmin(2:min(end,nbsym+1)));
479         lsym = indmin(1);
480     else
481         lmax = [fliplr(indmax(1:min(end,nbsym-1))),1];
482         lmin = fliplr(indmin(1:min(end,nbsym)));
483         lsym = 1;
484     end
485 end
486
487 if indmax(end) < indmin(end)
488     if x(end) < x(indmax(end))
489         rmax = fliplr(indmax(max(end-nbsym+1,1):end));
490         rmin = fliplr(indmin(max(end-nbsym,1):end-1));
491         rsym = indmin(end);
492     else

```



```

493     rmax = [lx, fliplr(indmax(max(end-nbsym+2,1):end))];
494     rmin = fliplr(indmin(max(end-nbsym+1,1):end));
495     rsym = lx;
496     end
497 else
498     if x(end) > x(indmin(end))
499         rmax = fliplr(indmax(max(end-nbsym,1):end-1));
500         rmin = fliplr(indmin(max(end-nbsym+1,1):end));
501         rsym = indmax(end);
502     else
503         rmax = fliplr(indmax(max(end-nbsym+1,1):end));
504         rmin = [lx, fliplr(indmin(max(end-nbsym+2,1):end))];
505         rsym = lx;
506     end
507 end
508
509 tlmin = 2*t(lsym)-t(lmin);
510 tlmax = 2*t(lsym)-t(lmax);
511 trmin = 2*t(rsym)-t(rmin);
512 trmax = 2*t(rsym)-t(rmax);
513
514 % in case symmetrized parts do not extend enough
515 if tlmin(1) > t(1) || tlmax(1) > t(1)
516     if lsym == indmax(1)
517         lmax = fliplr(indmax(1:min(end,nbsym)));
518     else
519         lmin = fliplr(indmin(1:min(end,nbsym)));
520     end
521     if lsym == 1
522         error('bug')
523     end
524     lsym = 1;
525     tlmin = 2*t(lsym)-t(lmin);
526     tlmax = 2*t(lsym)-t(lmax);
527 end
528
529 if trmin(end) < t(lx) || trmax(end) < t(lx)
530     if rsym == indmax(end)
531         rmax = fliplr(indmax(max(end-nbsym+1,1):end));
532     else
533         rmin = fliplr(indmin(max(end-nbsym+1,1):end));
534     end
535     if rsym == lx
536         error('bug')
537     end
538     rsym = lx;
539     trmin = 2*t(rsym)-t(rmin);
540     trmax = 2*t(rsym)-t(rmax);
541 end
542
543 zlmax = z(lmax);
544 zlmin = z(lmin);
545 zrmax = z(rmax);
546 zrmin = z(rmin);
547
548 tmin = [tlmin t(indmin) trmin];
549 tmax = [tlmax t(indmax) trmax];
550 zmin = [zlmin z(indmin) zrmin];
551 zmax = [zlmax z(indmax) zrmax];
552 end
553
554 %-----
555 %extracts the indices of extrema
556 function [indmin, indmax, indzer] = extr(x,t)
557
558 if nargin==1
559     t=1:length(x);
560 end
561
562 m = length(x);
563
564 if nargin > 2
565     x1=x(1:m-1);

```

```

566 x2=x(2:m);
567 indzer = find(x1.*x2<0);
568
569 if any(x == 0)
570     iz = find( x==0 );
571     indz = [];
572     if any(diff(iz)==1)
573         zer = x == 0;
574         dz = diff([0 zer 0]);
575         debz = find(dz == 1);
576         finz = find(dz == -1)-1;
577         indz = round((debz+finz)/2);
578     else
579         indz = iz;
580     end
581     indzer = sort([indzer indz]);
582 end
583 end
584
585 d = diff(x);
586
587 n = length(d);
588 d1 = d(1:n-1);
589 d2 = d(2:n);
590 indmin = find(d1.*d2<0 & d1<0)+1;
591 indmax = find(d1.*d2<0 & d1>0)+1;
592
593
594 % when two or more successive points have the same value we consider only one extremum in the middle of
    the constant area
595 % (only works if the signal is uniformly sampled)
596
597 if any(d==0)
598
599     imax = [];
600     imin = [];
601
602     bad = (d==0);
603     dd = diff([0 bad 0]);
604     debs = find(dd == 1);
605     fins = find(dd == -1);
606     if debs(1) == 1
607         if length(debs) > 1
608             debs = debs(2:end);
609             fins = fins(2:end);
610         else
611             debs = [];
612             fins = [];
613         end
614     end
615     if length(debs) > 0
616         if fins(end) == m
617             if length(debs) > 1
618                 debs = debs(1:(end-1));
619                 fins = fins(1:(end-1));
620             else
611                 debs = [];
622                 fins = [];
623             end
624         end
625     end
626 end
627 lc = length(debs);
628 if lc > 0
629     for k = 1:lc
630         if d(debs(k)-1) > 0
631             if d(fins(k)) < 0
632                 imax = [imax round((fins(k)+debs(k))/2)];
633             end
634         else
635             if d(fins(k)) > 0
636                 imin = [imin round((fins(k)+debs(k))/2)];
637             end

```

```

638     end
639     end
640 end
641
642 if length(imax) > 0
643     indmax = sort([indmax imax]);
644 end
645
646 if length(imin) > 0
647     indmin = sort([indmin imin]);
648 end
649
650 end
651 end
652
653 %-----
654
655 function ort = io(x,imf)
656 % ort = IO(x,imf) computes the index of orthogonality
657 %
658 % inputs : - x : analyzed signal
659 %          - imf : empirical mode decomposition
660
661 n = size(imf,1);
662
663 s = 0;
664
665 for i = 1:n
666     for j = 1:n
667         if i~=j
668             s = s + abs(sum(imf(i,:).*conj(imf(j,:)))/sum(x.^2));
669         end
670     end
671 end
672
673 ort = 0.5*s;
674 end
675 %-----
676
677 function [x,t,sd,sd2,tol,MODE_COMPLEX,ndirs,display_sifting,sdt,sd2t,r,
678         imf,k,nbit,NbIt,MAXITERATIONS,FIXE,FIXE_H,MAXMODES,INTERP,mask] = init(varargin)
679
680 x = varargin{1};
681 if nargin == 2
682     if isstruct(varargin{2})
683         inopts = varargin{2};
684     else
685         error('when using 2 arguments the first one is the analyzed signal X and the second one is a struct
686             object describing the options')
687     end
688 elseif nargin > 2
689     try
690         inopts = struct(varargin{2:end});
691     catch
692         error('bad argument syntax')
693     end
694 end
695 % default for stopping
696 defstop = [0.05,0.5,0.05];
697
698 opt_fields =
699     {'t','stop','display','maxiterations','fix','maxmodes','interp','fix_h','mask','ndirs','complex_version'};
700 defopts.stop = defstop;
701 defopts.display = 0;
702 defopts.t = 1:max(size(x));
703 defopts.maxiterations = 2000;
704 defopts.fix = 0;
705 defopts.maxmodes = 0;
706 defopts.interp = 'spline';
707 defopts.fix_h = 0;
708 defopts.mask = 0;

```

```

709 defopts.ndirs = 4;
710 defopts.complex_version = 2;
711
712 opts = defopts;
713
714
715
716 if(nargin==1)
717     inopts = defopts;
718 elseif nargin == 0
719     error('not enough arguments')
720 end
721
722
723 names = fieldnames(inopts);
724 for nom = names'
725     if ~any(strcmpi(char(nom), opt_fields))
726         error(['bad option field name: ',char(nom)])
727     end
728     if ~isempty(eval(['inopts.',char(nom)])) % empty values are discarded
729         eval(['opts.',lower(char(nom)), ' = inopts.',char(nom),';'])
730     end
731 end
732
733 t = opts.t;
734 stop = opts.stop;
735 display_sifting = opts.display;
736 MAXITERATIONS = opts.maxiterations;
737 FIXE = opts.fix;
738 MAXMODES = opts.maxmodes;
739 INTERP = opts.interp;
740 FIXE_H = opts.fix_h;
741 mask = opts.mask;
742 ndirs = opts.ndirs;
743 complex_version = opts.complex_version;
744
745 if ~isvector(x)
746     error('X must have only one row or one column')
747 end
748
749 if size(x,1) > 1
750     x = x.';
751 end
752
753 if ~isvector(t)
754     error('option field T must have only one row or one column')
755 end
756
757 if ~isreal(t)
758     error('time instants T must be a real vector')
759 end
760
761 if size(t,1) > 1
762     t = t.';
763 end
764
765 if (length(t)~=length(x))
766     error('X and option field T must have the same length')
767 end
768
769 if ~isvector(stop) || length(stop) > 3
770     error('option field STOP must have only one row or one column of max three elements')
771 end
772
773 if ~all(isfinite(x))
774     error('data elements must be finite')
775 end
776
777 if size(stop,1) > 1
778     stop = stop';
779 end
780
781 L = length(stop);

```

```

782 if L < 3
783     stop(3)=defstop(3);
784 end
785
786 if L < 2
787     stop(2)=defstop(2);
788 end
789
790
791 if ~ischar(INTERP) || ~any(strcmpi(INTERP,{'linear','cubic','spline'}))
792     error('INTERP field must be ''linear'', ''cubic'', ''pchip'' or ''spline''')
793 end
794
795 %special procedure when a masking signal is specified
796 if any(mask)
797     if ~isvector(mask) || length(mask) ~= length(x)
798         error('masking signal must have the same dimension as the analyzed signal X')
799     end
800
801     if size(mask,1) > 1
802         mask = mask.';
803     end
804     opts.mask = 0;
805     imf1 = emd(x+mask,opts);
806     imf2 = emd(x-mask,opts);
807     if size(imf1,1) ~= size(imf2,1)
808         warning('emd:warning',[ 'the two sets of IMFs have different sizes: ',int2str(size(imf1,1)), ' and
            ',int2str(size(imf2,1)), ' IMFs.'])
809     end
810     S1 = size(imf1,1);
811     S2 = size(imf2,1);
812     if S1 ~= S2
813         if S1 < S2
814             tmp = imf1;
815             imf1 = imf2;
816             imf2 = tmp;
817         end
818         imf2(max(S1,S2),1) = 0;
819     end
820     imf = (imf1+imf2)/2;
821
822 end
823
824
825 sd = stop(1);
826 sd2 = stop(2);
827 tol = stop(3);
828
829 lx = length(x);
830
831 sdt = sd*ones(1,lx);
832 sd2t = sd2*ones(1,lx);
833
834 if FIXE
835     MAXITERATIONS = FIXE;
836     if FIXE_H
837         error('cannot use both ''FIX'' and ''FIX_H'' modes')
838     end
839 end
840
841 MODE_COMPLEX = ~isreal(x)*complex_version;
842 if MODE_COMPLEX && complex_version ~= 1 && complex_version ~= 2
843     error('COMPLEX_VERSION parameter must equal 1 or 2')
844 end
845
846
847 % number of extrema and zero-crossings in residual
848 ner = lx;
849 nzs = lx;
850
851 r = x;
852
853 if ~any(mask) % if a masking signal is specified "imf" already exists at this stage

```

```

854   imf = [];
855 end
856 k = 1;
857
858 % iterations counter for extraction of 1 mode
859 nbit=0;
860
861 % total iterations counter
862 NbIt=0;
863 end
864 %-----

```

A.2 Algoritmo EEMD

```

1 function [modos, its]=eemd(x,Nstd,NR,MaxIter, relTol)
2 %-----
3 %WARNING: this code needs to include in the same
4 %directoy the file emd.m developed by Rilling and Flandrin.
5 %This file is available at %http://perso.ens-lyon.fr/patrick.flandrin/emd.html
6 %We use the default stopping criterion.
7 %We use the last modification: 3.2007
8 % -----
9 % OUTPUT
10 %   modos: contain the obtained modes in a matrix with the rows being the modes
11 %   its:   contain the iterations needed for each mode for each realization
12 %
13 % INPUT
14 %   x: signal to decompose
15 %   Nstd: noise standard deviation
16 %   NR: number of realizations
17 %   MaxIter: maximum number of sifting iterations allowed.
18 % -----
19 % Syntax
20 %
21 %   modos=eemd(x,Nstd,NR,MaxIter)
22 %   [modos its]=eemd(x,Nstd,NR,MaxIter)
23 % -----
24 % NOTE:   if Nstd=0 and NR=1, the EMD decomposition is obtained.
25 % -----
26 % EEMD was introduced in
27 % Wu Z. and Huang N.
28 % "Ensemble Empirical Mode Decomposition: A noise-assisted data analysis method".
29 % Advances in Adaptive Data Analysis. vol 1. pp 1-41, 2009.
30 % -----
31 % The present EEMD implementation was used in
32 % M.E.TORRES, M.A. COLOMINAS, G. SCHLOTTHAUER, P. FLANDRIN,
33 % "A complete Ensemble Empirical Mode decomposition with adaptive noise,"
34 % IEEE Int. Conf. on Acoust., Speech and Signal Proc. ICASSP-11, pp. 4144-4147, Prague (CZ)
35 %
36 % in order to compare the performance of the new method CEEMDAN with the performance of the EEMD.
37 %
38 % -----
39 % Date: June 06,2011
40 % Authors: Torres ME, Colominas MA, Schlotthauer G, Flandrin P.
41 % For problems with the code, please contact the authors:
42 % To: macolominas(AT)bioingenieria.edu.ar
43 % CC: metorres(AT)santafe-conicet.gov.ar
44 % -----
45 % This version was run on Matlab 7.10.0 (R2010a)
46 %-----
47
48 desvio_estandar=std(x);
49 x=x/desvio_estandar;
50 xconruido=x+Nstd*randn(size(x));
51 [modos, o, it]=emd(xconruido,'MAXITERATIONS',MaxIter, 'STOP', relTol);
52 modos=modos/NR;
53 iter=it;
54 if NR>=2
55     for i=2:NR

```

```

56     xconruido=x+Nstd*randn(size(x));
57     [temp, ort, it]=emd(xconruido,'MAXITERATIONS',MaxIter, 'STOP', relTol);
58     temp=temp/NR;
59     lit=length(it);
60     [p liter]=size(iter);
61     if lit<liter
62         it=[it zeros(1,liter-lit)];
63     end;
64     if liter<lit
65         iter=[iter zeros(p,lit-liter)];
66     end;
67
68     iter=[iter;it];
69
70     [filas columnas]=size(temp);
71     [alto ancho]=size(modos);
72     diferencia=alto-filas;
73     if filas>alto
74         modos=[modos; zeros(abs(diferencia),ancho)];
75     end;
76     if alto>filas
77         temp=[temp;zeros(abs(diferencia),ancho)];
78     end;
79
80     modos=modos+temp;
81 end;
82 end;
83 its=iter;
84 modos=modos*desvio_estandar;

```

A.3 Algoritmo CEEMDAN

```

1 function [modos its]=ceemdan(x,Nstd,NR,MaxIter, relTol)
2
3 % WARNING: for this code works it is necessary to include in the same
4 %directoy the file emd.m developed by Rilling and Flandrin.
5 %This file is available at %http://perso.ens-lyon.fr/patrick.flandrin/emd.html
6 %We use the default stopping criterion.
7 %We use the last modification: 3.2007
8 %
9 % This version was run on Matlab 7.10.0 (R2010a)
10 %-----
11 % INPUTs
12 % x: signal to decompose
13 % Nstd: noise standard deviation
14 % NR: number of realizations
15 % MaxIter: maximum number of sifting iterations allowed.
16 %
17 % OUTPUTs
18 % modos: contain the obtained modes in a matrix with the rows being the modes
19 % its: contain the sifting iterations needed for each mode for each realization (one row for each
    realization)
20 %-----
21 % Syntax
22 %
23 % modos=ceemdan(x,Nstd,NR,MaxIter)
24 % [modos its]=ceemdan(x,Nstd,NR,MaxIter)
25 %
26 %-----
27 % This algorithm was presented at ICASSP 2011, Prague, Czech Republic
28 % Please, if you use this code in your work, please cite the paper where the
29 % algorithm was first presented.
30 % If you use this code, please cite:
31 %
32 % M.E.TORRES, M.A. COLOMINAS, G. SCHLOTTHAUER, P. FLANDRIN,
33 % "A complete Ensemble Empirical Mode decomposition with adaptive noise,"
34 % IEEE Int. Conf. on Acoust., Speech and Signal Proc. ICASSP-11, pp. 4144-4147, Prague (CZ)
35 %
36 % -----

```

```

37 % Date: June 06,2011
38 % Authors: Torres ME, Colominas MA, Schlotthauer G, Flandrin P.
39 % For problems with the code, please contact the authors:
40 % To: macolominas(AT)bioingenieria.edu.ar
41 % CC: metorres(AT)santafe-conicet.gov.ar
42 % -----
43
44 x=x(:)';
45 desvio_x=std(x);
46 x=x/desvio_x;
47
48 modes=zeros(size(x));
49 temp=zeros(size(x));
50 aux=zeros(size(x));
51 acum=zeros(size(x));
52 iter=zeros(NR,round(log2(length(x))+5));
53
54 for i=1:NR
55     white_noise{i}=randn(size(x));%creates the noise realizations
56 end;
57
58 for i=1:NR
59     modes_white_noise{i}=emd(white_noise{i});%calculates the modes of white gaussian noise
60 end;
61
62 for i=1:NR %calculates the first mode
63     temp=x+Nstd*white_noise{i};
64     [temp, o, it]=emd(temp,'MAXMODES',1,'MAXITERATIONS',MaxIter, 'STOP', relTol);
65     temp=temp(1,:);
66     aux=aux+temp/NR;
67     iter(i,1)=it;
68 end;
69
70 modes=aux; %saves the first mode
71 k=1;
72 aux=zeros(size(x));
73 acum=sum(modes,1);
74
75 while nnz(diff(sign(diff(x-acum))))>2 %calculates the rest of the modes
76     for i=1:NR
77         tamanio=size(modes_white_noise{i});
78         if tamanio(1)>=k+1
79             noise=modes_white_noise{i}(k,:);
80             noise=noise/std(noise);
81             noise=Nstd*noise;
82             try
83                 [temp, o, it]=emd(x-acum+std(x-acum)*noise,'MAXMODES',1,'MAXITERATIONS',MaxIter, 'STOP',
84                     relTol);
85                 temp=temp(1,:);
86             catch
87                 it=0;
88                 temp=x-acum;
89             end;
90         else
91             [temp, o, it]=emd(x-acum,'MAXMODES',1,'MAXITERATIONS',MaxIter, 'STOP', relTol);
92             temp=temp(1,:);
93             aux=aux+temp/NR;
94             iter(i,k+1)=it;
95         end;
96         modes=[modes;aux];
97         aux=zeros(size(x));
98         acum=zeros(size(x));
99         acum=sum(modes,1);
100         k=k+1;
101     end;
102 modes=[modes;(x-acum)];
103 [a b]=size(modes);
104 iter=iter(:,1:a);
105 modes=modes*desvio_x;
106 its=iter;

```
