

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

Franklin Lima Santos
Área de Eletrônica Embarcada
SENAI CIMATEC
Av. Orlando Gomes, 1845, Piatã
Salvador - BA
Email: franklin.santos@fieb.org.br

Paulo César M. A. Farias
Eduardo F. de Simas Filho
Departamento de Engenharia Elétrica
Escola Politécnica da UFBA
R. Prof. Aristίδes Novis, 2, Federação
Salvador - BA
Emails: paulo.farias@ufba.br
eduardo.simas@ufba.br

Maria C. S. Albuquerque
Ivan C. Silva e Claudia T. T. Farias
Grupo de Pesq. em Ensaios Não Destrutivos
Instituto Federal da Bahia
R. Emídio dos Santos, Salvador-BA
Emails: cleaalbuquerque@ifba.edu.br
ivan.silva@ifba.edu.br
c.farias@ifba.edu.br

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%).

Keywords—Transformada de Hilbert-Huang, processamento de sinais, ultrassom, ensaios não destrutivos, redes neurais.

I. INTRODUÇÃO

A combinação de materiais para obtenção de estruturas com características específicas tem recebido atenção de engenheiros e cientistas ao longo dos anos [1]. 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 [2].

Devido ao nível de criticidade dessas aplicações, o diagnóstico de possíveis defeitos oriundos do processo de fabricação se torna algo imprescindível para assegurar o bom funcionamento dos equipamentos e sistemas onde esses materiais são aplicados.

Ao longo dos anos, diversas técnicas foram criadas e aperfeiçoadas para permitir o diagnóstico eficaz de defeitos em estruturas mecânicas para várias aplicações, envolvendo, por exemplo, a verificação de descontinuidades¹ em soldas

¹Convém salientar que neste trabalho, os termos “descontinuidade” e “defeito” são utilizados indistintamente, uma vez que o que os diferencia é a aplicação normativa. Caso os limites toleráveis para determinada aplicação seja ultrapassada, descontinuidade tornar-se-á um defeito.

metálicas, fraturas em tanques de armazenamento ou ainda inspeção de ferramentas na indústria automobilística [3].

Dentre as múltiplas técnicas de ensaios não destrutivos (END) existentes, como o raio-x e as técnicas magnéticas, a inspeção por ultrassom combina boa eficiência na detecção de defeitos, aplicabilidade em diferentes tipos de materiais e segurança intrínseca para o operador, sendo umas das técnicas mais utilizadas para detecção, localização e medição das falhas em estruturas [4].

Neste tipo de ensaio, uma onda mecânica é emitida dentro do material por meio de um transdutor 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 por outro transdutor ou, em alguns casos, pelo mesmo transdutor. No caso da técnica TOFD (do inglês, *Time Of Flight Diffraction*), o tempo de retorno da onda permite detectar descontinuidades no material e, além disso, como os diferentes tipos de descontinuidades produzem sinais com características distintas, é possível a identificação do tipo específico de descontinuidade. A Figura 1 mostra como as ondas se comportam no material ao utilizar-se a técnica TOFD.

A onda incidente no material sofrerá reflexão no fundo do corpo de prova inspecionado, o que produz o chamado eco de fundo, além de uma onda lateral. As descontinuidades no material também produzirão difrações que podem ser captadas pela sonda receptora e visualizadas com auxílio de um osciloscópio ou outro equipamento específico. A Figura 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. Além disso, há um dispositivo que permite o registro e armazenamento dos sinais medidos para posterior utilização. Aparelhos mais modernos permitem a visualização em tempo real da estrutura




Figura 1: Ilustração da técnica TOFD.

desses materiais por meio de imagens bidimensionais.



Figura 2: Equipamento que permite a aplicação da técnica TOFD (Disponível em <https://www.olympus-ims.com>).

A partir dos sinais medidos, é possível aplicar técnicas de processamento de sinais que permitem automatizar o processo de diagnóstico de descontinuidades, mitigando possíveis imprecisões devido a inexperiência do operador e aumentando, por conseguinte, a eficácia do diagnóstico.

Alguns trabalhos [5]–[7] têm aplicado as técnicas de processamento de sinais com este objetivo, seguindo, em geral, a cadeia de processamento ilustrada na Figura 3.




Figura 3: Cadeia de processamento do sinal.

Este trabalho propõe avaliar a utilização da Transformada de Hilbert-Huang (HHT) como ferramenta para extração de características dos sinais de ultrassom obtidos com a técnica TOFD, uma vez que ela se apresenta como ferramenta útil na análise de dados não lineares e não estacionários [8]. As assinaturas obtidas a partir da HHT são utilizadas numa rede neural convencional do tipo *perceptron* multicamadas para classificação, permitindo, por conseguinte, a identificação dos diversos tipos de defeito.

A organização do trabalho é a que segue: na Seção II a transformada de Hilbert-Huang é apresentada, além disso uma breve discussão sobre redes neurais é feita. A Seção III está dedicada à descrição do procedimento experimental, enquanto a aplicação da HHT pode ser vista na Seção IV e o processo

de classificação utilizando redes neurais por ser visto na Seção V. Resultados e discussões podem ser vistos na Seção VI. Por fim, as conclusões do trabalho podem ser vistas na Seção VII.

II. FUNDAMENTAÇÃO TEÓRICA

Os processo físicos naturais são não-lineares e não-estacionários e, portanto, as técnicas convencionais de processamento de sinais fornecem uma abordagem limitada para análise destes processos [9]. Entende-se por sinal estacionário, um sinal cujas propriedades estatísticas são invariantes a translações temporais.

Alguns dos atuais métodos disponíveis estão voltados para aplicações que são lineares e não-estacionárias, ou ainda não-lineares e estacionárias [9], faltando uma abordagem que permita o tratamento adequado de sinais que apresentem ambas características.

Neste contexto, surge a transformada de Hilbert-Huang (ou, em inglês, *Hilbert-Huang Transform*, HHT) que combina a análise espectral em espaços de Hilbert (do inglês, *Hilbert Spectrum Analysis*, HSA), a partir da transformada de Hilbert (TH), e a decomposição de modo empírico (do inglês, *Empirical Mode Decomposition*, EMD), 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).

A. Transformada de Hilbert-Huang (HHT)

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

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

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

A partir de $y(t)$ é possível definir uma função analítica² $z(t)$, tal que $z(t) = x(t) + iy(t)$ ou, na forma polar, $z(t) = a(t)e^{i\theta(t)}$, onde

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

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

$$\omega(t) = \frac{d\theta(t)}{dt}. \quad (3)$$

1) *Decomposição de modo empírico (EMD)*: Conforme apresentado em [10], [11], o método de decomposição de modo empírico (do inglês *Empirical Mode Decomposition*, EMD) se torna necessário 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

²Uma 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 .

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 dado 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 Functions*, IMF).

A IMF é uma função que satisfaz as seguintes condições [12]:

- o número de máximos e mínimos e o número de cruzamentos em zero devem ser iguais, ou diferentes em, no máximo, 1 unidade, para um dado conjunto de dados;
- em qualquer ponto, a média dos envelopes definido pelos mínimos locais e pelos máximos locais deve ser zero.

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

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

A Figura 4 mostra um sinal aleatório e seus envelopes superior e inferior obtidos a partir da interpolação dos pontos de máximo e mínimo, respectivamente, bem como a média obtida entre tais envelopes.




Figura 4: Decomposição de modo empírico aplicada a um sinal [9].

O processo de peneiramento tem dois objetivos: eliminar sobreposições de modos de vibração³ e 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, e o segundo para o caso em que duas oscilações vizinhas tenham amplitudes muito diferentes [9]. Portanto, este procedimento tem de ser repetido quantas vezes for necessário.

No procedimento acima, h_1 deve ser tratada como uma IMF primitiva, mas na próxima rodada do procedimento, h_1 tornar-se-á o dado, como segue:

$$h_{11} = h_1 - m_{11}, \quad (4)$$

onde:

m_{11} é a média dos envelopes superior e inferior obtidos a partir da interpolação dos pontos máximos e mínimos, respectivamente, de h_1 .

Generalizando,

$$h_{1k} = h_{1(k-1)} - m_{1k} \quad (5)$$

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

$$c_1 = h_{1k} \quad (6)$$

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 [8], [11]: o teste de convergência de Cauchy, onde o parâmetro

$$SD_k = \frac{\sum_{t=0}^T |h_{k-1}(t) - h_k(t)|^2}{\sum_{t=0}^T h_{k-1}^2} \quad (7)$$

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 no 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 [9]. Em [8], 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 , pode ser encontrada. De maneira geral, c_1 possui o componente de menor período do sinal, que pode então ser retirada do sinal original, ou seja,

$$r_1 = x(t) - c_1. \quad (8)$$

³tradução livre para “riding waves”.

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

$$\begin{aligned} r_2 &= r_1 - c_2 \\ &\vdots \\ r_n &= r_{n-1} - c_n, \end{aligned} \quad (9)$$

até que r_n 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 [8].

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 [8].

Somando as equações 8 e 9, obtém-se

$$x(t) = \sum_{j=1}^n c_j + r_n, \quad (10)$$

e, portanto, a decomposição do dado em n modos empíricos é alcançada e o resíduo r_n pode ser obtido, sendo uma constante ou uma tendência para a média.

B. 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 instantânea de cada modo de vibração seja encontrada. O dado original pode então ser escrito como:

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j(t) \exp \left[i \int \omega_j(t) dt \right] \right\}, \quad (11)$$

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 dado em uma expansão de Fourier é dada por:

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j e^{i\omega_j t} \right\}, \quad (12)$$

onde: a_j e ω_j são constantes.

Comparando-se 11 e 12, pode-se compreender que as IMFs representam uma generalização da expansão de Fourier, 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.

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

$$h(\omega) = \int_0^T H(\omega, t) dt, \quad (13)$$

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 [13].

C. Redes Neurais Artificiais (RNA)

Redes neurais artificiais são modelos computacionais baseados 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 , e a sua saída, $y(t)$, é dada por

$$y(t) = h \left(\sum_{i=1}^n w_i x_i + b_i \right), \quad (14)$$

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.

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 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 5.




Figura 5: Arquitetura de uma rede neural do tipo MLP.

III. PROCEDIMENTO EXPERIMENTAL

O arranjo experimental sugerido por [5] pode ser visto na Figura 6. 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 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:

- Sonda: Olympus C543-SM
 - frequência central: 5 MHz
- Gerador de pulsos: Olympus 5077PR
- Osciloscópio: Tektronix TDS-2024B
 - frequência de amostragem de 250 MHz

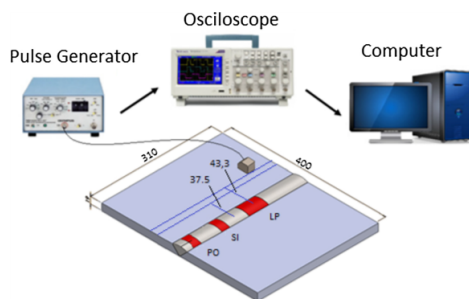


Figura 6: Arranjo experimental usado para obtenção dos dados.

A. Corpo de prova

Foi utilizado um corpo de prova de aço carbono SAE 1020 com dimensões 1000x500x15mm, 5mm, soldado através do processo de soldagem ao arco elétrico MIG, TIG e eletrodo revestido. Durante o procedimento foram inseridos os defeitos ao longo do cordão de solda, de maneira deliberada separado por regiões: falta de fusão (FF), inclusão de escória (IC), trinca (TC) e porosidade (PO). 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 50 x 15,5
- Condições: sem defeito (SD), falta de fusão (FF), inclusão de escória (IC), porosidade (PO) e trinca (TC)

A Figura 7 mostra a disposição dos defeitos inseridos no corpo de prova.




Figura 7: Corpo de prova

Como é possível observar, há diferenças na dinâmica do sinal para cada defeito, bem como para a situação sem defeito. A Figura 8 mostra as formas de onda para os diferentes defeitos presentes no material.

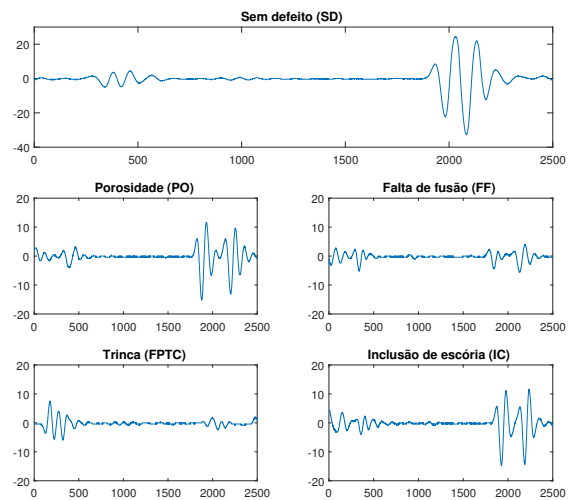


Figura 8: Formas de onda para os diversos tipos de defeito.

Essas diferenças foram analisadas por [5]–[7] em termos de assinaturas espectrais, obtidas a partir da transformada de Fourier do sinal, mas carece de informações sobre o que seriam as harmônicas fisicamente.

IV. TRANSFORMADA DE HILBERT-HUANG EM SINAIS DE ULTRASSOM

Os métodos tradicionais para análise de dados, como aqueles utilizados em [5]–[7], são baseados em suposições de que os dados medidos são lineares e estacionários.

Apesar dos resultados satisfatórios apresentados nos estudos supracitados, com eficiente classificação dos diferentes defeitos, a interpretação dos processos físicos pode estar comprometida quando se utiliza ferramentas lineares tais como as transformadas de Fourier e Wavelet. Neste contexto, a utilização da HHT em sinais de inspeção por ultrassom apresenta-se como uma alternativa adequada para compreensão dos fenômenos físicos envolvidos, bem como potencial ferramenta que pode aumentar a eficiência dos processos de decisão automatizada, favorecendo ao diagnóstico eficaz de falhas em estruturas mecânicas.

Diante do exposto, este trabalho visa o estudo e compreensão da aplicação da HHT em END baseados na técnica TOFD, afim de aprimorar o sistema de decisão e fornecer uma interpretação física do fenômeno físico.

A Figura 9 mostra a cadeia de processamento de sinais proposta para este trabalho.




Figura 9: Diagrama de processamento do sinal proposto.

Torna-se necessário compreender as informações originadas da aplicação da HHT, bem como estabelecer métricas para a comparação entre as diferentes abordagens descritas na literatura, permitindo um potencial aumento da precisão dos algoritmos de classificação.

Os gráficos da Figura 10 mostram as primeiras oito funções de modo intrínseco para uma amostra da condição sem defeito.

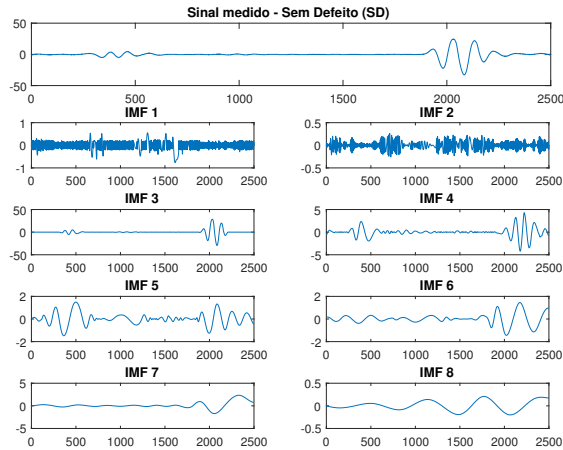


Figura 10: Sinal medido para a situação sem defeito e suas oito primeiras funções de modo intrínseco.

Por outro lado, os gráficos da Figura 11 mostram as primeiras IMFs para uma amostra nas situações com defeito.

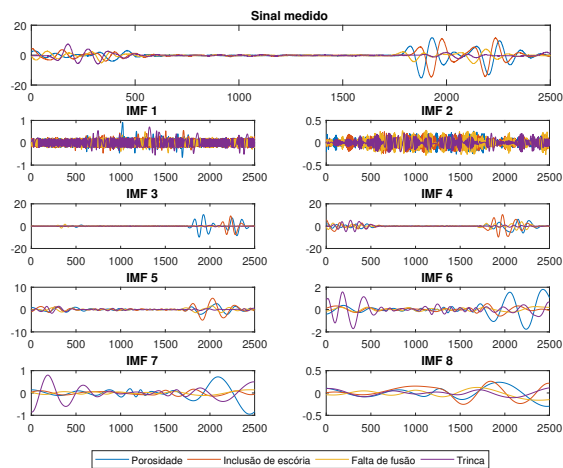
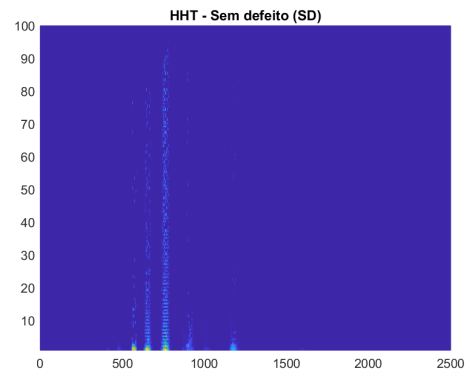



Figura 11: Primeiras oito IMFs geradas por meio do algoritmo EMD para as diversas situações de defeito.

É importante mencionar que, por se tratar de um processo numérico, o número de IMFs geradas variou entre 5 e 8 para as diversas condições.


Em seguida, aplicou-se a transformada de Hilbert, cujos espectros para as diversas condições de defeito, além condição sem defeito, podem ser vistos na Figura 12.




(a)




(b)



(c)



(d)



(e)

Figura 12: Espectro de Hilbert para a condição sem defeito (a) e para as condições com defeito (b-e).

É possível observar diferenças nas quantidades e nos valores de frequências instantâneas dos modos de vibração entre as diversas condições, além da intensidade dos mesmos, representados nos mapas em cores nas regiões mais densas e amareladas. A partir da análise espectral, nota-se que fisicamente a onda de ultrassom que penetra o material comporta-se de maneira diferente para as diversas condições, permitindo a criação ou não de novos modos de vibração com frequência e energia particulares.

V. CLASSIFICAÇÃO UTILIZANDO RNA

A quantidade de elementos dos vetores de frequência e energia instantâneas está diretamente relacionada com a quantidade de IMFs geradas, que variou entre as diversas condições como mencionado anteriormente. Afim de uniformizar os dados para classificação, o número de IMFs consideradas foi fixado em 5. Foram então selecionados 5 atributos de frequência instantânea e 5 atributos de energia instantânea. Todas as amostras possuem 2500 pontos.

Das 200 amostras disponíveis para cada defeito e para a condição sem defeito, 50% foram utilizadas para treinamento, 20% para validação e 30% para testes. Foram testados modelos com vários números de neurônios na camada oculta, sendo que os melhores resultados foram obtidos para $n = 50$ e $n = 200$. O modelo com menor número de neurônios se mostra mais adequado, caso o critério da parcimônia seja utilizado.

VI. RESULTADOS E DISCUSSÃO

Um classificador baseado numa rede neural do tipo *perceptron* multicamadas com uma camada oculta foi utilizado. As amostras foram permutadas aleatoriamente, sendo 50% selecionada para treinamento, 20% para validação e 30% para testes. O algoritmo utilizado para treinamento foi o *backpropagation*.

A Tabela I mostra a matriz de confusão para as diversas classes consideradas utilizando-se dados de teste. É possível observar que a rede classificou satisfatoriamente dados para todas as condições de defeito, além da condição sem defeito.

Tabela I: Matriz de confusão para a rede neural utilizada considerando os diversos defeitos.

		Classe predita				
		SD	PO	IC	TC	FF
Classe real	SD	20.0	0.0	0.7	0.0	0.0
	PO	0.0	20.0	1.3	0.0	0.3
	IC	0.3	0.7	17.0	0.0	0.3
	TC	0.0	0.0	0.0	19.3	1.0
	FF	0.0	0.3	1.0	0.3	17.3

Por outro lado, a Tabela II mostra os diferentes valores calculados para as métricas de sensibilidade (S), especificidade (E) e acurácia (A), definidas como:

$$S = \frac{V_P}{V_P + F_N} \quad E = \frac{V_N}{V_N + F_P} \quad A = \frac{V_P + V_N}{V_P + V_N + F_P + F_N}$$

onde V_P e V_N são verdadeiros positivos e verdadeiros negativos, respectivamente, e F_P e F_N são falsos positivos e falsos negativos, respectivamente.

Tabela II: Avaliação da classificação com base nos parâmetros de acurácia, especificidade e sensibilidade considerando dados de teste.

	Acurácia	Sensibilidade	Especificidade
SD	98,9%	96,8%	99,5%
PO	97,2%	92,3%	98,7%
IC	95,9%	92,7%	96,6%
TC	98,6%	95,1%	99,6%
FF	96,6%	91,2%	97,9%

A avaliação dos parâmetros do modelo (Tabela II) permite concluir uma boa generalização quando a rede é submetida a novos dados, especialmente nas condições sem defeito (SD) e trinca (TC).

Em [5], os autores fornecem um comparativo entre diferentes métodos de extração de características utilizando 100 dos 2500 coeficientes disponíveis para o mesmo conjunto de

dados utilizado neste trabalho. A comparação é feita a partir do produto das eficiências (PE), definido pela Eq. 15:

$$PE = \sqrt[N]{\prod_{i=1}^N E_{fi}} \quad (15)$$

onde a eficiência $E_{fi} = 1$ indica 100% de acurácia na classificação.

A Figura 13 mostra as curvas ROC (do inglês, *Receiver Operating Characteristic*) para as diversas classes consideradas no trabalho.

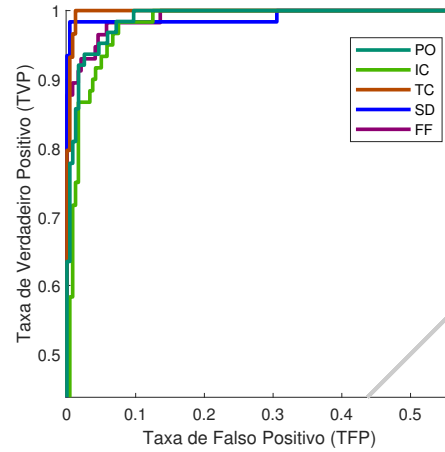


Figura 13: Curva ROC.

Vê-se que todas as classes tiveram desempenho satisfatório.

A Tabela III exhibe os valores encontrados em [5] e adiciona ainda os valores referentes à HHT, calculados neste trabalho. Convém salientar que o valor do PE calculado para a HHT não considera a eficiência relacionada ao defeito “trinca (TC)”, uma vez que [5] não tratou deste defeito.

Tabela III: Comparação usando o produto de eficiências para diversos métodos de extração de características.

	SD	PO	IC	TC	FF	PE
Nenhum	66,7	63,6	44,1	–	42,4	53,1
DFT	100,0	95,0	85,0	–	100,0	94,8
DCT	100,0	90,0	85,0	–	100,0	93,5
DWT	85,0	95,0	90,0	–	90,0	89,9
HHT	98,9	97,2	95,9	98,6	96,6	97,4

Observa-se que HHT possui um desempenho superior à utilização da DFT (*Discrete Fourier Transform*), que em [5] foi considerada a melhor técnica para a aplicação.

VII. CONCLUSÕES

A aplicação de técnicas de processamento de sinais tem auxiliado satisfatoriamente no diagnóstico e identificação de falhas em estruturas diversas, o que permite não só melhorias na eficiência do processo de manufatura, mas também potencializa o aumento da qualidade do produto.

Este trabalho propôs a utilização da transformada de Hilbert-Huang como ferramenta para extração de características em sinais de ultrassom obtidos a partir da técnica TOFD.

Num procedimento experimental, utilizando-se uma chapa de aço carbono soldada, foram obtidas 200 amostras para cada uma das quatro condições de defeito inseridos deliberadamente na solda (porosidade, inclusão de escória, falta de fusão e trinca), além de 200 amostras para uma condição onde a solda não apresentava defeito algum.

A aplicação do método de decomposição empírico (EMD) permitiu a obtenção das funções de modo intrínseco para cada uma amostras e em seguida aplicou-se a transformada de Hilbert, gerando espectro de Hilbert para cada uma das condições.

Os atributos obtidos a partir da aplicação da HHT (frequência e energia instantâneas) foram utilizados numa rede neural *perceptron* multicamadas após normalização e seleção da quantidade mínima de atributos: 5 atributos relacionados à frequência instantânea e 5 atributos relacionados à energia instantânea. O produto das eficiências para o modelo com 200 neurônios na camada interna foi de 97,4%, apresentando resultado superior aos dados de [5], em que o uso da DFT atingiu 94,8%.

Próximos passos incluem a avaliação da redução de atributos utilizando técnicas como por exemplo a Análise de Componentes Principais não linear (do inglês, *Non-linear Principal Component Analysis*, PCA).

REFERÊNCIAS

- [1] C. Zweben, *Composite Materials*. American Cancer Society, 2015, ch. 10, pp. 1–37. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781118985960.meh110>
- [2] S. Gholizadeh, “A review of non-destructive testing methods of composite materials,” *Procedia Structural Integrity*, vol. 1, pp. 50 – 57, 2016, xV Portuguese Conference on Fracture, PCF 2016, 10-12 February 2016, Paco de Arcos, Portugal. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2452321616000093>
- [3] C. D. Lockard, “Anomaly detection in radiographic images of composite materials via crosshatch regression,” Ph.D. dissertation, Mills College, 2015.
- [4] J. L. B. C. Veiga, A. A. d. Carvalho, I. C. d. Silva, and J. M. A. Rebello, “The use of artificial neural network in the classification of pulse-echo AND TOFD ultra-sonic signals,” *Journal of the Brazilian Society of Mechanical Sciences AND Engineering*, vol. 27, pp. 394 – 398, 12 2005. [Online]. Available: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1678-58782005000400007&nrm=iso
- [5] F. Cruz, E. Simas Filho, M. Albuquerque, I. Silva, C. Farias, and L. Gouvêa, “Efficient feature selection for neural network based detection of flaws in steel welded joints using ultrasound testing,” *Ultrasonics*, vol. 73, pp. 1 – 8, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0041624X16301500>
- [6] M. A. Oliveira, E. F. Simas Filho, I. C. Silva, M. C. S. Albuquerque, C. T. T. Farias, and L. C. Silva, “Detecção de novidades na classificação de defeitos em junta soldada de aço sae1020,” *ConaEND - Congresso Nacional de Ensaio Não Destrutivos e Inspeção*, 2016.
- [7] E. Simas Filho, M. M. S., P. Farias, M. C. Albuquerque, I. C. Silva, and C. T. Farias, “Flexible decision support system for ultrasound evaluation of fiber–metal laminates implemented in a dsp,” *NDT & E International*, vol. 79, pp. 38 – 45, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0963869515001322>
- [8] N. E. Huang, M.-L. C. Wu, S. R. Long, S. S. Shen, W. Qu, P. Gloersen, and K. L. Fan, “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*, vol. 459, no. 2037, pp. 2317–2345, 2003. [Online]. Available: <http://rspa.royalsocietypublishing.org/content/459/2037/2317>
- [9] N. E. Huang, *Introduction to the Hilbert-Huang transform AND its related mathematical problems*, ch. CHAPTER 1, pp. 1–26. [Online]. Available: https://www.worldscientific.com/doi/abs/10.1142/9789814508247_0001
- [10] N. Huang, Z. Shen, and S. R. Long, “A new view of nonlinear water waves: The hilbert spectrum,” *Annual Review of Fluid Mechanics*, vol. 31, no. 1, pp. 417–457, 1999. [Online]. Available: <https://doi.org/10.1146/annurev.fluid.31.1.417>
- [11] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, “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*, vol. 454, no. 1971, pp. 903–995, 1998. [Online]. Available: <http://rspa.royalsocietypublishing.org/content/454/1971/903>
- [12] M. Stork, “Hilbert-huang transform and its applications in engineering and biomedical signal analysis milan stork,” 2012.
- [13] N. E. Huang and W. Zhaohua, “A review on hilbert-huang transform: Method and its applications to geophysical studies,” *Reviews of Geophysics*, vol. 46, no. 2. [Online]. Available: <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2007RG000228>