

Avaliação de Diferentes Técnicas de Pré Processamento para um Sistema Neural de Apoio à Decisão em Inspeções por Ultrassom

Luana T. Macedo, Maria Cléa S. de Albuquerque, Ivan C. da Silva,
 Cláudia T. T. de Farias
*Laboratório de Ensaios Não Destrutivos,
 Instituto Federal da Bahia*
 Salvador, Brasil
 ltmacedo00@gmail.com; cleaalbuquerque@ifba.edu.br;
 ivan.silva@ifba.edu.br; cfarias@ifba.edu.br

Eduardo F. Simas Filho e Vitor R. de Britto
*Departamento de Engenharia Elétrica e de Computação,
 Universidade Federal da Bahia*
 Salvador, Brasil
 eduardo.simas@ufba.br; vitorrb@ufba.br

Resumo — Para garantir a confiabilidade de juntas soldadas, a combinação da técnica ultrassônica ToFD (*Time of Flight Diffraction*) às de análise computacional, que envolvem processamento de sinais e reconhecimento de padrões, dinamiza e assegura eficiência nos resultados da inspeção. Por se tratar de um ensaio não destrutivo, não há mudanças nas propriedades químicas, físicas e mecânicas do material, tornando-se possível identificar defeitos decorrentes dos processos de soldagem. Neste trabalho, as transformadas discreta de Fourier (DFT), do Cosseno (DCT) e Hilbert-Huang (HHT) foram usadas para processar sinais ultrassônicos obtidos pela técnica ultrassônica ToFD em uma junta soldada de aço SAE 1020. Os sinais pré-processados por DCT, DFT e HHT foram compactados através da análise de componentes principais (PCA), antes de serem utilizados como entrada para um classificador neural. A metodologia proposta permitiu identificar defeitos de solda com elevada taxa de acertos na classificação. Dentre as técnicas de pré processamento utilizadas, a DCT apresentou melhor desempenho na classificação, com 99,7% de eficiência.

Keywords — *técnicas de pré processamento, reconhecimento de padrões, ToFD, redes neurais.*

I. INTRODUÇÃO

Os ensaios não destrutivos representam um conjunto de técnicas essenciais aos processos industriais, uma vez que não influenciam a estrutura física e química dos materiais. Dentre estes, o ultrassom possui grande aplicabilidade que inclui detecção e dimensionamento de descontinuidades, correlação com propriedades mecânicas, e medição de espessura [1,2].

Devido a facilidade de automatização, a técnica ultrassônica ToFD (do inglês *Time of Flight Diffraction* ou tempo de percurso da onda difratada) vem sendo cada vez mais utilizada nas intervenções preditivas, principalmente na análise de defeitos em cordões de solda [2]. A inspeção envolve o uso de dois transdutores angulares, sendo um deles responsável pela emissão de feixes de ultrassom, paralelos e inclinados em relação à superfície. Além dos fenômenos de reflexão e transmissão, ocorre também a difração sônica. A identificação das ondas difratadas pelo transdutor receptor permite a detecção das descontinuidades [2, 3].

Apesar dos avanços com a técnica ultrassônica ToFD, não é possível identificar com precisão o tipo de defeito.

O uso de técnicas de inteligência computacional representa um avanço para identificação e classificação de defeitos detectados por técnicas ultrassônicas [3].

Através da transformada discreta do cosseno, é possível haver a compactação da energia do sinal, sendo concentrada em componentes de baixa frequência dos dados [4]. O uso da transformada discreta de Fourier, permite representar o sinal como soma de senos e cossenos [5]. Já a transformada de Hilbert-Huang faz com que qualquer conjunto de dados possa ser decomposto em um número finito de componentes mais simples [6].

Neste trabalho propõe-se comparar o desempenho de sistemas automáticos de classificação neural, usando como entrada sinais pré-processados pelas transformadas discreta do cosseno, Fourier, e Hilbert-Huang, com o objetivo de identificar padrões de defeitos em juntas soldadas. Para combinar de forma eficiente as informações obtidas, os dados, antes de serem alimentados ao classificador neural, serão pré processados através da análise de componentes principais (PCA – *Principal Component Analysis*), com o objetivo de reduzir sua dimensionalidade e consequentemente obter uma maior precisão na classificação dos sinais.

II. REFERENCIAL TEÓRICO

A. Técnica Ultrassônica ToFD

Devido a possível presença de falhas estruturais nos equipamentos mecânicos industriais, a realização periódica de inspeções nas estruturas para detecção de descontinuidades internas é essencial para evitar danos irreversíveis às edificações. A técnica ultrassônica ToFD, permite dimensionar precisamente a altura, comprimento e profundidade da descontinuidade, além de ter um excelente custo benefício, sendo utilizada principalmente para inspeção de juntas soldadas de topo entre chapas, durante a fabricação de equipamentos ou da manutenção periódica, como também na inspeção de vasos de pressão, torres, tanques, reatores, caldeiras.

O funcionamento do ensaio é baseado no princípio físico da difração das ondas ultrassônicas, usando dois transdutores angulares, conforme ilustrado na Figura 1. Os transdutores emissor e receptor são responsáveis por emitir e receber os pulsos sônicos simultaneamente, sendo estes, a onda lateral, propagada horizontalmente na superfície inspecionada, e o eco de fundo, no interior da peça. Os ecos

intermediários surgem quando a onda difrata em uma descontinuidade no interior da zona de inspeção [1,2,4].




Figura 1 - Propagação da onda em cordão de solda refletindo numa descontinuidade, adaptado de [4].

A imagem obtida pela técnica ultrassônica ToFD é bidimensional (D-Scan), em escala de cinza, conforme Figura 2, com as amplitudes positivas, representadas em cores claras e as negativas, em cores escuras. A imagem D-Scan representa um conjunto de sinais A-scan adjacentes (ecos ultrassônicos com a amplitude em função do tempo), obtidos enquanto os cabeçotes se movimentam.




Figura 2 - Propagação da onda em cordão de solda refletindo numa descontinuidade, visto em D-Scan e conjunto de sinais A-Scan, adaptado de [4].

Os sinais ultrassônicos obtidos por meio da técnica ultrassônica ToFD, podem conter ruídos. Neste sentido, ferramentas de processamento digital de sinais vêm sendo cada vez mais utilizadas para melhor classificação dos sinais recebidos e redução de ruídos após inspeção [3].

B. Transformada Discreta do Cosseno

A transformada discreta do cosseno é bastante utilizada para realização de processamentos digitais de imagem para melhor compreensão dos dados, pois consegue compactar energia, tendo a maior parte do sinal concentrado em componentes de baixa frequência da transformada. Sendo sua característica a expressão de uma sequência finita de pontos de dados como uma soma de funções do cosseno, oscilando em diferentes frequências. Permitindo que os dados sejam representados como coeficientes de frequência dos seus componentes [5].

C. Transformada Discreta de Fourier

A utilização do cálculo das séries de Fourier, para realização das transformadas permite a representação do sinal periódico como somas de senos e cossenos.

Com a aplicação da transformada discreta de Fourier, é possível acessar as informações no domínio do sinal estudado [6].

D. Transformada de Hilbert-Huang

A transformada de Hilbert-Huang é a junção da Decomposição em Modo empírico (EMD ou *Empiric Mode Decomposition*) e da Análise Espectral de Hilbert desses componentes, sendo um método projetado para análise de dados de processos não-lineares e não-estacionários.

O método EMD permite que qualquer conjunto de dados possa ser decomposto em um número finito de componentes mais simples, chamados de funções do modo intrínseco (IMF ou *Intrinsic Mode Function*), sendo usado para calcular a frequência instantânea de cada uma dessas funções. A função do modo intrínseco representa um modo oscilatório simples como contrapartida da função harmônica simples, mas é muito mais geral. Em vez de amplitude e frequência constantes em um componente harmônico simples, um IMF pode ter amplitude e frequência variáveis ao longo do eixo do tempo. Para ser classificada como uma IMF, a função precisa atender a três regras [7, 8], sendo elas:

- Em todo o conjunto de dados, o número de máximos junto com o número de mínimos deve se igualar ou diferir em no máximo um elemento do número de vezes que a função cruza o zero;
- Em qualquer ponto, o valor médio do envelope, definido pelos máximos locais e o envelope, definido pelos mínimos, é zero;
- A IMF gerada não pode ter nenhum máximo local abaixo de zero e nenhum mínimo local acima de zero.

A extração das IMF's através da decomposição em modo empírico, ocorre com a obtenção de todos os extremos locais, interpolando todos os máximos locais por uma spline cúbica (aproximação por polinômios seccionados, de grau 3, que permite garantir a continuidade da função até de sua derivada de segunda ordem, mesmo quando é especificada a derivada primeira da função a ser interpolada nos extremos do intervalo), formando o envelope superior. O procedimento é repetido nos mínimos locais, para a obtenção do envelope inferior. Após realizado o processo, é possível encontrar a média $m1(t)$ entre os respectivos envelopes, que subtraindo os dados da amostra $y(t)$, forma a primeira alternativa de IMF $h1$ [8,9]:

$$h1(t) = y(t) - m1(t) \quad (1)$$

O resultado final tem que satisfazer à condição de uma IMF. O sinal não deve ter nenhum máximo local abaixo de zero ou um mínimo local acima de zero. Caso não satisfaça, o processo deve ser repetido, utilizando o candidato a IMF no lugar dos dados iniciais, até que o número de zero-crossings e o de extremos, sejam iguais (podendo diferir no máximo de um) [7,8].

Com a análise espectral de Hilbert, é possível a obtenção de uma representação no domínio tempo-frequência através do cálculo da transformada de Hilbert de cada uma das funções obtidas na primeira parte por EMD. Após a obtenção da base de funções por EMD, é possível calcular a transformada de Hilbert de cada IMF e obter para cada IMF, a frequência instantânea e depois disso representar o sinal original através de um processo de síntese definido. Através dele é possível observar, para cada instante, o contributo em frequência e também a energia associada a cada par (tempo-frequência).

E. Análise de Componentes Principais - (PCA)

A análise dos componentes principais (PCA, do inglês Principal Component Analysis), é uma ferramenta estatística muito utilizada para a redução de dimensionalidade, em grandes conjuntos de dados, enquanto mantém a maior variância possível. O procedimento é realizado através da criação de um conjunto de variáveis que representam uma combinação linear dos dados de entrada [10].

Dada uma matriz X $n \times p$, com n observações e p dimensões, sua matriz de covariância (Σ) é calculada para a extração dos autovalores e autovetores, que são dados pela equação 2:

$$(\Sigma - \lambda)v = 0 \quad (2)$$

Sendo v , o autovetor e λ , o correspondente autovalor da matriz de covariância.

Os autovalores, e os seus respectivos autovetores são ordenados a partir da maior variância da matriz X . As combinações lineares de X são então projetadas no conjunto de vetores ortonormais, definindo os componentes principais [11].

F. Redes Neurais Artificiais

Redes neurais artificiais são modelos matemáticos, cujo modo de aprendizado é inspirado no funcionamento do cérebro humano. Essas redes possuem um sistema de autoaprendizagem que melhora o seu desempenho à medida que ela é alimentada com novos dados [12,13].

A rede neural artificial, utilizada neste trabalho foi a do tipo perceptron de múltiplas camadas ou MLP (do inglês *multi-layer perceptron*). Neste tipo de RNA, os dados de entrada funcionam como estímulos para os neurônios. Na camada intermediária, os estímulos são realizados de acordo com o peso sináptico atribuído. Assim, os dados de saída da rede são determinados pela soma ponderada de todos os estímulos e seus respectivos pesos sinápticos ao longo de todas as camadas. Esse tipo de RNA é utilizada em problemas de reconhecimento de padrões, quando é necessário que a rede classifique entradas em um conjunto de categorias alvo. Os neurônios de saída podem classificar os vetores com precisão, dado o número de neurônios em suas camadas ocultas [14].

O processo de treinamento de uma rede neural a um conjunto de dados envolve três etapas, treino, validação. No treino, os pesos sinápticos ajustam-se aos valores de saída, de acordo com uma parcela do conjunto de dados. Durante a validação é avaliada a performance do modelo durante o ajuste dos parâmetros e, na etapa final, é feita a avaliação do aprendizado adquirido pela rede em uma nova parcela dos dados de entrada [15].

III. MATERIAL E METODOLOGIA

A. Material

O material utilizado para o desenvolvimento deste trabalho consistiu em uma chapa de aço SAE 1020. A chapa com dimensões de 1000 mm x 440 mm x 15,5 mm, com chanfro em V, foi soldada pelos processos de soldagem a arco elétrico TIG (*Tungsten Inert Gas*) na raiz, MIG (*Metal Inert Gas*), para o preenchimento e Eletrodo Revestido no acabamento.

Durante a soldagem, foram introduzidos alguns tipos de descontinuidades inerentes em soldas, como falta de fusão, falta de penetração, inclusão de escória, porosidade e trinca. Essas descontinuidades foram identificadas previamente por uma análise de Raios X e, posteriormente, pela técnica ultrassônica ToFD. Os conjuntos de sinais obtidos para cada descontinuidade e de uma região sem defeito foram processados por duas técnicas de processamento digital de sinais, as transformadas discreta do cosseno, Fourier e Hilbert-Huang e analisados estatisticamente através da análise de componentes principais, PCA. Ao final, o desempenho de um classificador neural, projetado para identificar as descontinuidades da solda e alimentado com os sinais, processados de forma digital e tratados estatisticamente, foi avaliado.

B. Metodologia

A metodologia empregada para o desenvolvimento deste trabalho pode ser descrita no fluxograma exibido na Figura 3, abaixo:




Figura 3 - Fluxograma com as etapas do trabalho.

A chapa foi dividida em 6 regiões: sem defeito (SD) e com os defeitos de solda, trinca (TR), inclusão de escória (IE), porosidade (PO), falta de penetração (FP) e falta de fusão (FF), conforme imagem apresentada na Figura 4.




Figura 4 - Chapa de aço SAE 1020, com a identificação da localização das classes de defeitos

A coleta dos sinais foi feita com 120 varreduras de inspeção na chapa soldada para a aquisição das imagens D-Scan, usando transdutores ultrassônicos ToFD, modelo 024V9W, com diâmetros de 10 milímetros e frequência central de 5 MHz.

Os elementos sensores foram colocados sobre sapatas com inclinação de 70°, com distância de separação (ou PCS, do inglês *Probe Center Separation*) de 38 mm. A aquisição dos sinais foi realizada utilizando o equipamento USM Vision 1.2 da General Electric®.

Foram obtidas 10 imagens D-Scan para cada região, totalizando 60 imagens, com as dimensões (50x200) pixels para o processamento, que podem ser visualizadas nas imagens “a” a “f” dispostas na Figura 5.




Figura 5 - Representação D-Scan de cada tipo de sinal: (a) sem defeito, (b) trinca, (c) porosidade, (d) falta de penetração, (e) falta de fusão e (f) inclusão de escória.

Para cada imagem D-Scan, 50 sinais A-Scan foram obtidos por meio do uso do software ImageJ®. Isso representou um total de 3000 sinais obtidos, em conjunto com sua respectiva matriz de dados, conforme representação exibida na Figura 6.

Através do MatLab® foram gerados os algoritmos das transformadas discretas do cosseno, Fourier e Hilbert-Huang responsáveis pelo pré processamento dos conjuntos de sinais A-scan, correspondentes a cada classe. Os coeficientes das respectivas técnicas de pré processamento foram então utilizados para alimentar o classificador automático.




Figura 6 - Representação A-scan de cada tipo de sinal: (a) sem defeito, (b) trinca, (c) porosidade, (d) falta de penetração, (e) falta de fusão e (f) inclusão de escória.

Foi desenvolvida uma rede neural artificial do tipo MLP (*Multilayer Perceptron*), em que o número de neurônios nas camadas ocultas foi definido a partir do cálculo de 2/3 do número de entradas somado ao número de saídas [16]. Para o projeto de cada classificador automático, 25% dos dados foram destinados para validação, 25% para teste e 50%, para treino.

Para avaliar o desempenho do classificador com um número menor de componentes de entrada, os coeficientes foram processados com a ferramenta PCA que reduziu a dimensionalidade de ambas as transformadas em 50 componentes principais. Foi então testada a eficiência do classificador automático para os mesmos sinais A-scan coletados.

IV. RESULTADOS

Foram aplicadas diferentes técnicas de pré processamento aos sinais ultrassônicos ToFD, a fim de extrair informações relevantes que pudessem ser utilizadas pelos classificadores neurais, para distinguir entre padrões defeituosos e não defeituosos.

As técnicas de pré processamento usadas foram as transformadas discreta do cosseno e de Fourier e a transformada de Hilbert-Huang.

A. Transformada Discreta do Cosseno

Os sinais obtidos durante a inspeção pela técnica ultrassônica ToFD foram processados pela transformada discreta do cosseno como representado na Figura 7, obtendo a seguintes representações para os resultados com e sem defeito:

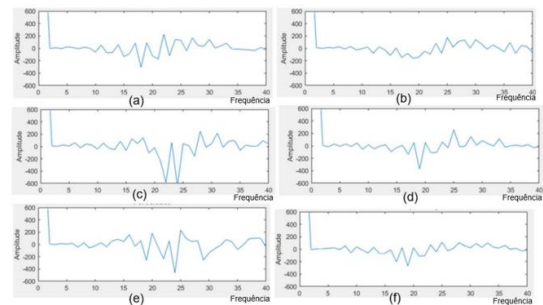


Figura 7 - Representação dos sinais após transformada discreta de Fourier de cada tipo de sinal: (a) sem defeito, (b) trinca, (c) inclusão de escória, (d) falta de fusão, (e) porosidade e (f) falta de penetração.

B. Transformada Discreta de Fourier

Para realização da comparação de dados os sinais foram processados pela transformada discreta de Fourier, obtendo a seguinte representação dos sinais para as diferentes configurações de defeitos e sem defeito como representado na Figura 8:




Figura 8 - Representação sinais após transformada discreta de Fourier de cada tipo de sinal: (a) sem defeito, (b) trinca, (c) porosidade, (d) falta de penetração, (e) falta de fusão e (f) inclusão de escória.

Foi observado que após a aplicação da transformada, a quantidade de pontos que cada sinal tinha, passou de 200 para 129.

C. Transformada de Hilbert-Huang

Para a transformada de Hilbert-Huang, o primeiro passo foi a realização da decomposição em modo empírico ou EMD (*Empirical Mode Decomposition*), através da qual foram geradas as respectivas funções de modo intrínseco ou IMF's (*Intrinsic Mode Function*) para cada região da solda, conforme exibidas nas Figuras de 9 a 14:




Figura 9 – IMF's para o sinal sem defeito.




Figura 10 – IMF's para o sinal com trinca.




Figura 11 – IMF's para o sinal com porosidade.




Figura 12 – IMF's para o sinal com falta de penetração.




Figura 13 – IMF's para o sinal com falta de fusão.




Figura 14 – IMF's para o sinal com inclusão de escória.

A partir de cada IMF, os espectros de Hilbert foram extraídos, conforme exibidos nas imagens da Figura 15:

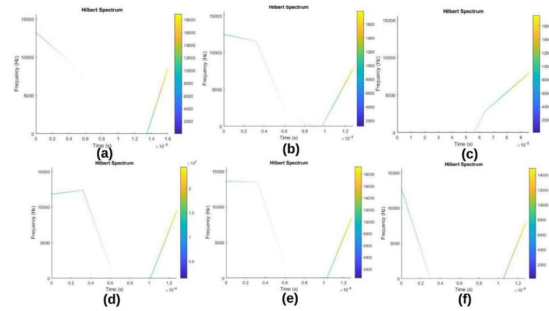


Figura 15 - Representação do Espectro de Hilbert para cada tipo de sinal: (a) sem defeito, (b) trinca, (c) porosidade, (d) falta de penetração, (e) falta de fusão e (f) inclusão de escória.

As coordenadas espectrais geradas mostram a diferença na variação da frequência instantânea de cada configuração de sinal.

Nas regiões com trinca, falta de fusão e porosidade, a frequência foi mantida com uma variação menor no início do tempo, porém para outras configurações de defeito, houve uma queda muito brusca na frequência dos sinais. Nota-se também que na região com inclusão de escória, houve uma redução na escala do tempo passando de 10^{-4} para 10^{-5} , pois quando comparado com as demais configurações o tempo de variação da frequência para obtenção do espectro foi muito menor, não sendo visível na escala anterior. Redução de Dimensionalidade

A análise dos componentes principais foi aplicada aos coeficientes das transformadas discreta do cosseno, Fourier e Hubert-Huang, reduzindo as suas dimensionalidades que originalmente eram de 200, 129 e 200 pontos, mantendo as variâncias em 87%, 91,4% e 87% respectivamente.

D. Classificador Automático

Os 6 conjuntos de sinais pré processados (DCT, DCT após aplicação do PCA, DFT, DFT após aplicação da PCA, transformada de Hilbert-Huang e transformada de Hilbert-Huang com aplicação da PCA) foram utilizados como entrada para os classificadores automáticos, sendo realizados 5 treinamentos da rede para cada tipo de alimentação.

Cada matriz foi dividida em duas classes, reais (classificação verdadeira dos resultados) e as previstas (classificações que o modelo estimou). O número de acertos para cada classe é demonstrado na diagonal principal da matriz, e os demais, os erros de classificação. A eficiência do classificador é demonstrada nas últimas linha e coluna da matriz de confusão.

Abaixo, nas figuras de 16 a 21, são apresentadas as matrizes de confusão obtidas a partir dos classificadores neurais de múltiplas camadas para os 6 conjuntos de dados.

CLASSIFICAÇÃO REAL	SD	TR	IE	PO	FF	FP	CLASSIFICAÇÃO PREDITA
	SD	58 15,5%	1 0,3%	0 0,0%	0 0,0%	0 0,0%	
TR	0 0,0%	66 16,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100%
IE	0 0,0%	0 0,0%	64 17,1%	0 0,0%	0 0,0%	1 0,3%	98,5%
PO	0 0,0%	0 0,0%	0 0,0%	70 18,2%	0 0,0%	0 0,0%	100%
FF	0 0,0%	0 0,0%	0 0,0%	0 0,0%	58 15,5%	0 0,0%	100%
FP	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	63 16,8%	100%
	100%	98,4%	100%	100%	90,2%	98,4%	99,5%
	0,0%	1,0%	0,0%	0,0%	0,3%	1,0%	0,0%

Figura 16 – Matriz de confusão para os sinais processados pela DCT sem PCA.

CLASSIFICAÇÃO REAL	SD	52 13,9%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100% 0,0%
	TR	0 0,0%	68 18,1%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100% 0,0%
	IE	0 0,0%	0 0,0%	64 17,1%	0 0,0%	0 0,0%	0 0,0%	100% 0,0%
	PO	0 0,0%	0 0,0%	0 0,0%	62 16,5%	0 0,0%	1 0,3%	98,4% 0,0%
	FF	0 0,0%	0 0,0%	0 0,0%	0 0,0%	67 17,9%	0 0,0%	100% 0,0%
	FP	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	63 16,3%	100% 0,0%
		100% 0,0%	100% 0,0%	100% 0,0%	100% 0,0%	100% 0,0%	98,4% 16,3%	99,7% 0,0%
	SD	TR	IE	PO	FF	FP		
		CLASSIFICAÇÃO PREDITA						

Figura 17 – Matriz de confusão para os sinais processados pela DCT com PCA.

CLASSIFICAÇÃO REAL	SD	67 17,9%	3 0,8%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	97,5% 0,0%
	TR	0 0,0%	63 16,8%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100% 0,0%
	IE	0 0,0%	0 0,0%	54 14,4%	0 0,0%	0 0,0%	1 0,3%	98,2% 0,0%
	PO	0 0,0%	0 0,0%	0 0,0%	66 18,0%	0 0,0%	0 0,0%	100% 0,0%
	FF	0 0,0%	1 0,3%	0 0,0%	1 0,3%	61 16,3%	1 0,3%	95,3% 0,0%
	FP	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	2 0,5%	96,6% 14,9%
		100% 0,0%	94,4% 6,0%	100% 0,0%	98,5% 1,5%	95,3% 4,7%	98,2% 1,8%	97,6% 0,0%
	SD	TR	IE	PO	FF	FP		
		CLASSIFICAÇÃO PREDITA						

Figura 18 – Matriz de confusão para os sinais processados pela DFT sem PCA.

CLASSIFICAÇÃO REAL	SD	79 21,4%	1 0,3%	0 0,0%	0 0,0%	0 0,0%	2 0,5%	96,3% 0,0%
	TR	0 0,0%	59 13,8%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	96,2% 0,0%
	IE	0 0,0%	0 0,0%	64 17,1%	0 0,0%	0 0,0%	0 0,0%	98,5% 0,0%
	PO	0 0,0%	0 0,0%	0 0,0%	61 16,3%	0 0,0%	0 0,0%	100% 0,0%
	FF	0 0,0%	2 0,5%	0 0,0%	3 0,8%	55 14,7%	0 0,0%	91,7% 0,0%
	FP	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	55 14,7%	100% 0,0%
		100% 0,0%	94,3% 5,7%	100% 0,0%	93,8% 6,2%	100% 0,0%	93,2% 6,8%	97,1% 0,0%
	SD	TR	IE	PO	FF	FP		
		CLASSIFICAÇÃO PREDITA						

Figura 19 – Matriz de confusão para os sinais processados pela DFT com PCA.

CLASSIFICAÇÃO REAL	SD	65 17,3%	2 0,5%	0 0,0%	1 0,3%	0 0,0%	3 0,8%	91,5% 0,0%
	TR	2 0,5%	42 11,2%	1 0,3%	0 0,0%	5 1,3%	7 1,9%	93,7% 0,0%
	IE	0 0,0%	3 0,8%	55 14,7%	1 0,3%	0 0,0%	0 0,0%	93,2% 0,0%
	PO	1 0,3%	1 0,3%	3 0,8%	40 10,7%	2 0,5%	1 0,3%	83,3% 10,7%
	FF	1 0,3%	5 1,3%	2 0,5%	8 2,1%	46 12,3%	2 0,5%	71,9% 28,1%
	FP	6 1,6%	13 3,5%	2 0,5%	6 1,6%	2 0,5%	47 12,5%	61,8% 38,2%
		86,7% 0,0%	63,6% 36,4%	87,3% 12,7%	71,4% 28,6%	83,6% 16,4%	78,3% 21,7%	78,7% 21,3%
	SD	TR	IE	PO	FF	FP		
		CLASSIFICAÇÃO PREDITA						

Figura 20 – Matriz de confusão para os sinais processados pela HHT sem PCA.

CLASSIFICAÇÃO REAL	SD	70 18,7%	1 0,3%	0 0,0%	0 0,0%	1 0,3%	1 0,3%	95,9% 0,0%
	TR	2 0,5%	55 14,7%	2 0,5%	2 0,5%	1 0,3%	1 0,3%	87,3% 12,7%
	IE	0 0,0%	0 0,0%	59 15,7%	0 0,0%	1 0,3%	0 0,0%	98,3% 1,7%
	PO	2 0,5%	1 0,3%	1 0,3%	41 10,8%	11 2,9%	2 0,5%	70,7% 29,3%
	FF	0 0,0%	2 0,5%	1 0,3%	6 1,6%	48 13,6%	2 0,5%	82,3% 17,7%
	FP	0 0,0%	6 1,6%	0 0,0%	0 0,0%	4 1,1%	49 13,1%	83,1% 16,9%
		96,6% 3,4%	84,6% 15,4%	93,7% 6,3%	83,7% 16,3%	73,9% 26,1%	89,1% 10,9%	86,7% 13,3%
	SD	TR	IE	PO	FF	FP		
		CLASSIFICAÇÃO PREDITA						

Figura 21 – Matriz de confusão para os sinais processados pela HHT com PCA.

Conforme pode ser observado nas Tabelas 15 e 16, os classificadores que usaram como entrada os coeficientes processados pela transformada discreta do cosseno obtiveram o melhor desempenho em geral. No entanto, é importante mencionar que o classificador com redução de dimensionalidade, usando PCA, apresentou um percentual de erro menor em comparação aos demais. Isso pode ser

atribuído às características específicas dessa transformada, que se mostrou mais adequada para a representação e análise dos padrões de defeitos presentes nos sinais de solda, identificados pela técnica ultrassônica ToFD, no presente trabalho.

É relevante destacar que houve um erro na classificação da falta de penetração em todos os classificadores. Esse desvio indicou que o modelo de classificação criado teve dificuldade em distinguir esse tipo de defeito, resultando em uma classificação equivocada quanto a esse aspecto específico. Ao comparar os resultados quanto as transformadas discreta do cosseno e de Fourier, foi constatado que a região sem defeito obteve um acerto de 100% nos classificadores alimentados com e sem PCA. Isso indica que os classificadores tiveram um desempenho excelente ao identificar corretamente a ausência de defeitos nessa região específica.

Esses resultados destacam a eficiência das técnicas de pré-processamento supracitadas na detecção e classificação de sinais de regiões sem defeitos, podendo constituir uma base segura para a avaliação de integridade de componentes e estruturas. Pode-se notar também que a aplicação do PCA no classificador alimentado pela transformada de Hilbert-Huang, aumentou em 8% o seu desempenho na identificação das regiões, comprovando a importância de utilização da técnica para análise dos dados.

V. CONCLUSÃO

A comparação entre os classificadores neurais (Tabela 1), usando como entrada os sinais pré-processados pelas transformadas discreta do cosseno, Fourier e de Hilbert-Huang, revelou que a transformada dos cossenos apresentou maior confiabilidade na identificação dos defeitos, em cerca de 99,7% e 99,5%, com e sem a redução da dimensionalidade, usando PCA. Esse resultado pode ser atribuído às características específicas dessa transformada, que se mostraram mais adequadas para a representação e análise dos padrões de defeitos identificados no presente trabalho.

Tabela 1- Desempenho dos classificadores

TIPO DE PROCESSAMENTO	DESEMPENHO DO CLASSIFICADOR
Transformada Discreta do Cosseno (Sem PCA)	99,5%
Transformada Discreta do Cosseno (Com PCA)	99,7%
Transformada Discreta de Fourier (Sem PCA)	97,6%
Transformada Discreta de Fourier (Com PCA)	97,1%
Transformada de Hilbert-Huang (Sem PCA)	78,7%
Transformada de Hilbert-Huang (Com PCA)	86,7%

Em trabalhos futuros, pretende-se comparar os resultados ora obtidos com o desempenho de outros classificadores.

Agradecimentos

Os autores agradecem à FAPESB e ao CNPq pelo apoio financeiro.

Referências

[1] JOLIVEIRA, Damião. ENSAIOS NÃO DESTRUTIVOS: Fundamentos e Aplicações. 2019. 48 p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Mecânica) - Universidade Federal da Paraíba, Paraíba, 2019. Disponível em:

<<https://repositorio.ufpb.br/jspui/bitstream/123456789/25387/1/TCC> -

- DAMI%20-17.05.19%20vers%20A3o%20final.pdf.> Acesso em 15/05/2023.
- [2] JESUS, A. V. S.; LUNA, W. H. D.; ALBUQUERQUE, M. C. S.; SIMAS FILHO, E. F.; SILVA, I. C.; FARIAS, C.T.T. Uso de Redes Neurais Artificiais Alimentadas com Sinais Ultrassônicos na Classificação de Defeitos em Juntas Soldadas por Meio da Técnica ToFD em Diferentes Configurações. In: Coteq 2019, 2019, Rio de Janeiro. Anais do Coteq, 2019.
- [3] PRAVEEN ANGAM; K. VIJAYAREKHA; ABRAHAM, Saju T; et al. Fourier Analysis of Ultrasonic TOFD Signals for Defect Detection in Austenitic Stainless Steel Welds. ResearchGate. Disponível em: <https://www.researchgate.net/publication/261009678_Fourier_Analysis_of_Ultrasonic_TOFD_Signals_for_Defect_Detection_in_Austenitic_Stainless_Steel_Welds> Acesso em 15/05/2023.
- [4] RUNGRUENG, Chanvich. Comparison of Detection and Height Sizing Ability of Planar Defect in Thick Wall Weld Steel Between PAUT and TOFD Techniques. International Journal of Recent Engineering Research and Development, [S. l.], p. 1-18, 1 abr. 2019.
- [5] LIVERA, Antony. Transformada Discreta do Coseno (DCT). UNIVERSIDADE FERNANDO PESSOA MULTIMÉDIA, Portugal, p. 1, 15 maio 2014. Disponível em: <http://multimedia.ufp.pt/codecs/compressao-com-perdas/metodos-baseados-em-transformadas/transformada-discreta-do-coseno-dct/>. Acesso em 15/05/2023.
- [6] PUPIN, Josiana. Introdução às Séries e Transformadas de Fourier e Aplicações no Processamento de Sinais e Imagens. Orientador: Waldeck Schutzer. 2011. 82 p. TCC (Licenciatura) - Universidade Federal de São Carlos, [S. l.], 20/12/2011. Disponível em: <<https://www.dm.ufscar.br/dm/attachments/article/6/TCCJosiana.pdf>> Acesso em 15/05/2023.
- [7] PINTO, RUI. Novas abordagens ao estudo de sinais biomédicos: Análise em tempo-frequência e transformada de Hilbert-Huang. 2009. TESE (Doutorado) - Universidade de Lisboa, [S. l.], 2009. Disponível em: <https://repositorio.ul.pt/bitstream/10451/1827/1/ulsd58177_td_Rui_Pinto.pdf> Acesso em 15/05/2023.
- [8] CRESPO, Juliana. Utilização do método de decomposição empírico no processamento de dados de mobilidade urbana / Juliana Huther Albernaz Crespo. 2018. 57 f. Dissertação (mestrado) – Fundação Getúlio Vargas, Escola de Matemática Aplicada.
- [9] LYMBEROPOULOS, A. TÓPICOS ABORDADOS NESTA AULA INTRODUÇÃO DEFINIÇÃO TEORIA NO COMPUTADOR INTERPOLAÇÃO POLINOMIAL SPLINES CÚBICOS. [s.l.]: , [s.d.]. Disponível em: <<https://www.ime.usp.br/mat/2458/textos/splines.pdf>>. Acesso em 15/05/2023.
- [10] JOLLIFFE, I.T. Principal Component Analysis, 2nd ed., Springer, New York, USA, 2002.
- [11] VASCONCELOS, Simone. Introdução a Análise de Componentes Principais (ACP). Disponível em: < <http://www.ic.uff.br/~aconci/PCA-ACP.pdf>>. Acesso em 15/05/2023.
- [12] JESUS, A.; ALBUQUERQUE, M.C.S.; SIMAS FILHO, E.; SILVA, I., FARIAS, C.T.T. Detecção de Descontinuidades em Cordões de Solda Utilizando a Técnica Ultrassônica ToFD e Classificação de Defeitos Através de Redes Neurais Artificiais. ENCOM, Salvador. 2018.
- [13] JESUS, A. V. S.; BRITTO, L. M.; ALBUQUERQUE, M.C.S.; SIMAS FILHO, E.F.; SILVA, I. C.; FARIAS, C.T.T. Detecção de Descontinuidades em Cordões de Solda Utilizando a Técnica Ultrassônica ToFD e Classificação de Defeitos Através de Árvores de Decisão e Redes Neurais Artificiais. In: Congresso Nacional de Ensaio Não Destrutivos e Inspeção, 2018, São Paulo. Anais do ConaEND 2018a, 2018. v. 1. p. 1-10.
- [14] HAYKIN, S. Neural networks and learning machines, 3/E. [S.l.: s.n.], 2009.
- [15] AGGARWAL, C. C. Neural Networks and Deep Learning. 1ª edição. [S.l.] Springer, 2018, Cap 1.
- [16] HEATON, J. Introduction to Neural Networks with Java. Heaton Research, Incorporated; 2nd edition. October, 2008.