# Localização de Defeitos com Método Baseado em Deep Learning em Ensaios Não Destrutivos por Ultrassom<sup>\*</sup>

Andréia R. de Souza, Giovanni A. Guarneri, Dalcimar Casanova<sup>\*</sup> Daniel R. Pipa<sup>\*\*</sup> Thiago A. R. Passarin,<sup>\*\*\*</sup> Gustavo P. Pires<sup>\*\*\*\*</sup>

\* Programa de Pós Graduação em Engenharia Elétrica, UTFPR, Campus Pato Branco, PR (e-mails: andreia@alunos.utfpr.edu.br, giovanni@utfpr.edu.br, dalcimar@utfpr.edu.br)
\*\* Programa de Pós Graduação em Engenharia Elétrica e Informática Industrial, UTFPR, Campus Curitiba, PR (e-mail: danielpipa@utfpr.edu.br)
\*\*\* Departamento Acadêmico de Eletrotécnica, UTFPR, Campus Curitiba, PR (e-mail: passarin@utfpr.edu.br)
\*\*\*\* Centro de Pesquisa e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES), Rio de Janeiro, RJ (e-mail:gustavopires@petrobras.com.br)

Abstract: There are plenty of methods applicable to the analysis of ultrasonic signals that make it possible to characterize and locate flaws within objects. Among these methods, those that use image reconstruction stand out, because of the ease they provide in results visualization. Several algorithms based on different approaches aim at increasing ultrasound image quality. An approache that has been proposed for many applications and introduced in reconstruction of ultrasound images is deep learning. This paper presents a method for geometric location of flaws in a region of interest, from an image reconstructed using a deep neural network (DNN). For this purpose, simulated data of infinitesimal acoustic reflectors, that representing small flaws, were used to train and test a convolutional autoencoder neural network. The results show estimation errors in the order of 0.3167 mm for x axis and 7.9720  $\mu$ m for z axis as well as robustness to acquisition noise.

**Resumo**: Existem vários métodos aplicáveis à análise de sinais ultrassônicos que possibilitam a caracterização e localização de defeitos em objetos. Dentre tais métodos, destacam-se os que usam reconstrução de imagens, pois facilitam a visualização dos resultados. Nesse contexto, diversos algoritmos, com abordagens diferentes, objetivam melhorar a qualidade das imagens reconstruídas . Uma abordagem proposta em muitas aplicações e que começou a ser introduzida na reconstrução de imagens de ultrassom é a de aprendizagem profunda (deep learning). Este artigo apresenta um método de estimação das coordenadas para a localização geométrica de defeitos dentro de uma região de interesse, a partir de uma imagem reconstruída por meio de uma rede neural profunda (Deep Neural Network - DNN). Para tanto, dados simulados com refletores acústicos infinitesimais (representando pequenos defeitos) foram usados para treinar e validar uma rede neural do tipo autoencoder convolucional. Os resultados demonstram que o método faz estimativas das coordenadas geométricas dos refletores com erros da ordem de 0,3167 mm para o eixo x, e 7,9720  $\mu$ m para o eixo z, sendo também robusto ao ruído presente nos sinais de ultrassom.

*Keywords:* Flaw Location; Nondestructive testing; Ultrasound; Image Reconstruction; Deep Learning.

*Palavras-chaves:* Localização de defeitos; Ensaios Não Destrutivos; Ultrassom; Reconstrução de Imagens; Deep Learning.

# 1. INTRODUÇÃO

Inferir sobre a integridade de materiais e equipamentos auxilia no aprimoramento de processos e no controle de qualidade, que se tornaram fatores primordiais para o sucesso de qualquer atividade. Entre os diversos métodos existentes para atingir tal objetivo, destacam-se os ensaios não destrutivos (END) (Hellier, 2003). Dentre as técnicas de END existentes, aquelas baseadas em ultrassom são usadas para detectar defeitos e descontinuidades característicos do próprio processo de fabricação em diversos tipos de materiais, fazendo com que esse método seja amplamente utilizado na indústria. A facilidade de geração e recepção dos sinais ultrassônicos torna os sistemas de inspeção simplificados. Segundo Thompson and Thompson (1985), as vantagens dos ENDs por ultrassom são: a capacidade de penetração profunda do ultrassom no interior dos objetos sem excessiva atenuação e, principalmente, a capacidade dos sinais de retorno carregarem informações relacionadas com as características do material e de defeitos encontrados. Isso possibilita que esses defeitos sejam classificados e caracterizados de acordo com tamanho, forma, orientação e localização geométrica (Guarneri et al., 2017).

A caracterização de defeitos em objetos a partir da análise dos sinais ultrassônicos é um campo aberto para pesquisas. Dentre as numerosas técnicas encontradas na literatura, aquelas fundamentadas em imagens formadas a partir dos sinais de reflexão (i.e. eco) de pulsos ultrassônicos são muito utilizadas, pois facilitam a interpretação dos dados de inspeção pelos seres humanos (Thompson and Thompson, 1985; Schmerr, 1998). Esses métodos são chamados genericamente de algoritmos de *reconstrução de imagens* (von Bernus et al., 1993).

Uma abordagem que vem sendo proposta em diversas aplicações de processamento de sinais, e que recentemente está também sendo aplicada em END por ultrassom é a de *Deep Learning* utilizando *Deep Neural Networks* (DNN). Segundo Arthur Chapon (2019), existem várias vantagens em utilizar essa abordagem, dentre as quais a capacidade da técnica aprender simultaneamente sobre o ruído estatístico e o padrão de interesse do sinal, sem qualquer operação de extração de características, e também, a redução do impacto do ruído e das modificações dos padrões do eco por espalhamento.

Neste artigo, é proposto um método para a localização geométrica de refletores acústicos infinitesimais, que são uma forma simplificada de representar pequenos defeitos (Schmerr, 1998), a partir de imagens reconstruídas por uma DNN com arquitetura *autoencoder* de neurônios convolucionais. Embora o uso de DNN já esteja presente nas aplicações de processamento de imagens em outros domínios (Voulodimos et al., 2018), essa é uma forma inédita de se tratar a reconstrução de imagens no domínio dos END por ultrassom.

# 2. RECONSTRUÇÃO DE IMAGENS EM ENSAIOS POR ULTRASSOM

A reconstrução de imagens em END por ultrassom é definida como a obtenção de uma imagem a partir da reflexividade acústica de uma região de interesse (ROI). Para tal, um método computacional é aplicado no conjunto de sinais medidos por um sistema de inspeção que, normalmente, apresentam ruído de medição caracterizado como ruído branco gaussiano (von Bernus et al., 1993). A esses sinais dá-se o nome de A-scans. Um A-scan representa a amplitude dos ecos medidos em função do tempo, como mostrado na Figura 1a. O método mais simples para a reconstrução de imagens é o que gera a imagem chamada B-scan. Uma imagem B-scan representa graficamente uma seção transversal da ROI, produzida ao longo de uma linha de varredura, sendo composta por diversos A-scans, como mostrado na Figura 1b (Kino, 1987). Kino (1987) observa que as imagens B-scan têm como característica a baixa capacidade de distinção de dois pontos em um plano perpendicular ao do feixe. A qualidade das imagens B-scan também é afetada pelos efeitos de difração e de espalhamento das ondas ultrassônicas devido à geometria do transdutor.

Existem vários algoritmos de reconstrução de imagens, baseados em diferentes abordagens, que procuram mitigar os problemas das imagens *B-scan*. Entre essas abordagens, uma das mais utilizadas é a *Delay-and-Sum (DAS) beam-forming*. Os algoritmos tradicionais baseados na técnica DAS são o SAFT (*Synthetic Aperture Focusing Technique*) (Prine, 1972) e o TFM (*Total Focusing Method*) (Holmes et al., 2005). A Figura 1c mostra uma imagem reconstruída pelo algoritmo SAFT, enquanto que a Figura 1d é a imagem ideal de um refletor infinitesimal.



Figura 1. (a) Representação A-scan, (b) imagem B-scan,
(c) imagem reconstruída com o algoritmo SAFT e (d) imagem ideal de um refletor infinitesimal.

Existem também algoritmos baseados na resolução de problemas inversos, que consistem em encontrar uma imagem por meio da resolução de um sistema de equações no

 $<sup>\</sup>star\,$ Petróleo Brasileiro S/A



Figura 2. Diagrama de blocos do método de estimação de posição. A imagem *B-scan* pré-processada é fornecida à rede neural. A imagem resultante é usada para estimar a posição do defeito.

qual estão presentes os dados coletados e o modelo de aquisição do sistema de imageamento, como Lavarello et al. (2006), Guarneri et al. (2015) e Passarin et al. (2018). Tradicionalmente, tais algoritmos são implementados a partir de métodos analíticos, em que o problema é definido explicitamente, com domínio conhecido e cuidadosamente projetado para a solução.

Métodos que possibilitam determinar causas desconhecidas a partir de efeitos observados têm ampla aplicabilidade na solução de problemas em imagens. Nos últimos anos, a área de aprendizado de máquina, mais especificamente os métodos baseados em aprendizado profundo (i.e. *Deep Learning*) ganharam muito impulso na solução de problemas com imagem. O desempenho fornecido pelas abordagens analíticas foi, algumas vezes, superado pelas que usam DNNs (Luchies and Byram, 2018). A principal característica dos métodos baseados em *Deep Learning* é que tais métodos fazem uso de conjuntos de dados para aprender a solução desconhecida para o problema inverso, sem que sejam explicitamente programados para tal, ou seja, não requerem conhecimento prévio do problema a ser resolvido (Luchies and Byram, 2018).

Para o tratamento do problema de reconstrução de imagem por ultrassom proposto neste trabalho, fornece-se uma imagem *B-scan* (Figura 1b) como entrada a uma DNN do tipo *autoencoder* e espera-se como resultado uma imagem esparsa com um ponto unitário representando a posição do refletor infinitesimal na ROI (Figura 1d). Para tal, essa rede precisa ser treinada por um processo de otimização que busca minimizar a diferença entre o resultado previsto pelo modelo e suas respectivas saídas desejadas. Nas seções que seguem, são descritos os processos para o desenvolvimento do método (Seção 3); a avaliação dos seus resultados quanto à precisão na estimativa das coordenadas dos defeitos e à robustez em relação a presença de ruído nos sinais (Seção 4); e, por fim, as conclusões acerca do método e trabalhos futuros (Seção 5).

# 3. METODOLOGIA

A Figura 2 apresenta um diagrama de blocos que representa o método proposto para localização de defeitos. Esses blocos são descritos nas seções a seguir.

#### 3.1 Construção do conjunto de dados

O conjunto de dados para treinamento e teste do método proposto é composto por imagens *B-scan* criadas a partir do *software* simulador Field II (Jensen, 2004). Esse *software* simula a propagação e espalhamento de ondas ultrassônicas utilizando o modelo de Tupholme-Stepanishen para a resposta ao impulso espacial (Tupholme, 1969; Stepanishen, 1971a,b), que se baseia na teoria de sistemas lineares para encontrar o campo de ultrassom no caso de uma onda pulsada ou contínua.

Foram simuladas as respostas de um defeito infinitesimal em uma ROI com comprimento e largura de 20 mm. O meio simulado para a propagação das ondas ultrassônicas foi a água, com velocidade de propagação de 1480 m/s. O transdutor de ultrassom é do tipo *phased array* linear, com 32 elementos ativos com pulso de excitação cossenoidal modulado por uma Gaussiana, com frequência central de 5MHz, largura da banda fracionária (6 dB) de 50%, comprimento de cada elemento de 10 mm, largura de 0,7 mm e distância entre os centros dos elementos (*pitch*) de 0,4 mm. As imagens resultantes têm resolução de 6757x32.

O conjunto de dados é composto por 300 pares de imagens  $(X_i, Y_i)$  em que, i = 1, 2, ..., 300. O conjunto de entrada



Figura 3. CNN com arquitetura *autoencoder*. A imagem *B-scan* fornecida para a rede tem seus mapas de características compactados por um codificador e aumentados por uma rede decodificadora.

 $X_i$  contém as imagens *B*-scan simuladas com um único ponto refletor infinitesimal, com coordenadas **x** e **z** distribuídas aleatoriamente (distribuição uniforme) sobre a ROI. Para que os dados simulados representem com maior fidelidade os sinais obtidos por um sistema de inspeção por ultrassom, optou-se por adicionar ruído gaussiano branco com SNR=40 dB aos sinais *A*-scan (formadores das imagens *B*-scan). As imagens  $Y_i$  são matrizes com a mesma dimensão das imagens *B*-scan, em que apenas um elemento tem valor não nulo. Esse elemento não nulo representa as coordenadas corretas do ponto refletor infinitesimal na ROI.

### 3.2 Pré-processamento

Um processamento é feito nas imagens *B-scan* antes delas serem apresentadas como entradas da DNN. Esse préprocessamento tem por objetivo melhorar o aspecto visual das imagens, facilitando sua interpretação em etapas posteriores.

Para uma rede neural, é desejável que os valores de amplitude das imagens estejam entre 0 e 1. Portanto, uma das operações de pré-processamento realizadas pelo método é a normalização. Também foi feita a extração do envelope, resultando na magnitude dos valores absolutos dos sinais A-scan que compõem imagens B-scan.

#### 3.3 Modelo de DNN baseado em autoencoder

A escolha de uma arquitetura para resolver esse problema foi feita observando trabalhos de outras aplicações que utilizam a resolução de problemas inversos em imagens. Muitos trabalhos aplicam *autoencoders* convolucionais para a resolução de problemas inversos, tais como em *superresolution imaging* (Zeng et al., 2017), *compressed sensing* (Mousavi et al., 2015), *image denoising* (Mao et al., 2016) e *image restoration* (Jin et al., 2017).

A arquitetura com neurônios convolucionais se justifica pelo excelente desempenho das redes convolucionais (CNNs) para várias aplicações. Porém, o motivo do alto desempenho permanece praticamente sem resposta. Mc-Cann et al. (2017), em seu estudo, comentam algumas diferentes perspectivas teóricas que começam a explicar por que as CNNs são uma boa opção para resolver problemas inversos em imagens. Em linhas gerais, pode-se resumir em: (1) são aproximadores universais; (2) não linearidade intrínseca e; (3) suposta invariância a translações na imagem, ruído, mudança de frequência, rotação, entre outras.

Em um *autoencoder* convolucional, as imagens de entrada são compactadas espacialmente por uma rede codificadora e aumentadas novamente ao tamanho da imagem de saída por uma rede decodificadora. Para evitar que os *autoencoders* aprendam um mapeamento trivial, em que a entrada é copiada na saída, foi utilizada regularização por norma  $\ell_1$ .



Figura 4. Histograma dos erros de posição no conjunto de treinamento (a) para a coordenada horizontal (x) e (b) para a coordenada vertical da ROI (z). A partir dos valores desses histogramas foi possível identificar que havia um ...

A Figura 3 apresenta a arquitetura proposta para a aplicação de reconstrução de imagem em ENDs por ultrassom. A definição da arquitetura da rede foi realizada usando pesquisa empírica, sendo que outras arquiteturas do tipo *autoencoder* foram testadas e apresentaram resultados semelhantes.

Na primeira camada do codificador, aplicam-se 8 filtros convolucionais (Keras, 2020) à imagem de entrada. Para que a imagem resultante tivesse a característica de esparsidade desejada, adicionou-se à primeira camada regularização por norma  $\ell_1$ , com parâmetro de regularização  $\lambda$  $= 10^{-6}$ . A segunda camada do codificador é composta por 4 filtros convolucionais. A terceira camada tem como saída a imagem codificada (i.e. espaço latente), possuindo 2 filtros. Para o decodificador, usaram-se duas camadas, sendo a primeira de convolução em profundidade (Keras, 2020), em que aplicaram-se 2 filtros a cada um dos mapas de características do espaço latente, totalizando 4 filtros. Na segunda camada, usou-se convolução separável (que atua em cada canal de entrada separadamente seguida de uma convolução no sentido do ponto) (Keras, 2020). Nessa camada, mapas de características da entrada são unidos, formando um único canal de saída com função de ativação sigomóide. As demais camadas usaram função de ativação ReLU (Keras, 2020).

Para realizar o treinamento do modelo, o conjunto de dados descrito na Seção 3.1 foi dividido em conjuntos de treinamento e teste, pelo método de holdout, contendo 225 e 75 pares de imagens (X, Y), respectivamente. Assim como para a definição da arquitetura, os demais hiperparâmetros do modelo também foram definidos de maneira empírica utilizando busca randômica, sendo que para o parâmetro de regularização e a taxa de aprendizagem usou-se grid search. Os hiperparâmetros que obtiveram melhor resultado foram: 780 épocas, otimizador Adam, e taxa de aprendizagem de  $10^{-5}$ . A função de perda (loss) foi definida como o Erro Absoluto Médio (Mean Absolute Error - MAE), definido pela Equação (1)

$$MAE = \frac{1}{n} \sum_{i=0}^{n} |Y_i - \hat{Y}_i|, \qquad (1)$$

em que,  $Y_i$  é a imagem rótulo <br/>e $\hat{Y}_i$  é a imagem reconstruída pela rede.

# 3.4 Pós-processamento

Uma vez que uma imagem  $X_i$  seja apresentada à rede, sua saída  $\hat{Y}_i$  é obtida. As saídas inicialmente obtidas pela arquitetura *autoencoder* apresentaram valores de amplitude baixos. Para tanto, fez-se necessário, para uma melhor visualização dos resultados, aplicar funções de normalização pra o intervalo [0,1] e extração de envelope (magnitude dos valores absolutos dos sinais analíticos) às matrizes.

Na sequência, os índices da linha e da coluna com maior amplitude na imagem são identificados e tomados como a posição do defeito na imagem. A conversão desses índices para milímetros é efetuada pelas equações 2 e 3:

$$\hat{x} = x_i \Delta x + x_0 \,, \tag{2}$$

$$\hat{z} = z_i \Delta z + z_0 \,, \tag{3}$$

em que,  $x_i$  e  $z_i$  são os índices da imagem,  $\Delta x$  e  $\Delta z$ são as resoluções em cada dimensão da matriz e  $x_0$  e  $z_0$  as coordenadas do canto superior esquerdo da ROI. Considera-se o eixo x no sentido do comprimento e o eixo z no sentido da profundidade da região de interesse.

Uma pré-avaliação visual dos resultados, realizada com o modelo treinado, identificou a ocorrência de translação nos valores das posições estimadas pelo modelo quando comparadas aos resultados esperados. Para o conjunto de treinamento, observou-se uma distribuição nos valores de translação nas coordenadas mostrados nos histogramas da Figura 4.

A Tabela 1 apresenta a média, desvio padrão, mediana e moda que caracterizam esse comportamento.

Observou-se que as translações em z são muito pequenas, não havendo a necessidade de correção. Entretanto, como as translações em x são mais significativas, devido a



Figura 5. (a) Imagem *B-scan* fornecida à rede e (b) imagem reconstruída com a rede CNN treinada.



Figura 6. Erros médios de posicionamento para diferentes níveis de SNR (a) para a coordenada horizontal (x) e (b) para a coordenada vertical da ROI (z).

Tabela 1. Translações verificadas no conjunto de treinamento (mm).

Eixo	Média	Desvio Padrão	Mediana	Moda
x	$2,\!2417$	0,4916	1,8750	$1,\!8750$
z	0,0035	0,0025	0,0035	0,0059

baixa resolução nesse eixo, optou-se pela correção desse viés utilizando o valor da moda das translações em x de 1,875 mm, conforme a Tabela 1. Para tanto, adiciona-se à Equação 2 o termo  $x_c$  que faz a compensação da translação aprendida pela rede, conforme a Equação 4

$$\hat{x} = x_i \Delta x + x_0 - x_c \,. \tag{4}$$

# 4. RESULTADOS

Para validar o método proposto, foi utilizado o conjunto de teste. Como exemplo, na Figura 5a, é apresentado um exemplo de imagem *B-scan* fornecida como entrada X para a CNN. Enquanto a Figura 5b mostra a imagem  $\hat{Y}$  correspondente, reconstruída pela rede neural.

A posição estimada pela técnica para a imagem da Figura 5b foi  $\hat{x} = -6,25$  mm e  $\hat{z} = 26,778$  mm. A posição correta desse ponto é x = -6,25 mm e z = 26,778 mm, apresentando um erro nulo no posicionamento. O método foi aplicado a todas as 75 imagens do conjunto de teste e obtiveram-se os erros de posicionamento para todos os pontos desse conjunto. A média e desvio padrão dos erros nesse conjunto são de 0,3167 mm ± 0,4283 mm para as coordenadas do eixo x, e 7,9720  $\mu$ m ± 5,0225  $\mu$ m para as coordenadas do eixo z.

Como os sinais A-scan medidos por sistemas de inspeção contém ruídos de medição, fez-se necessário considerar a robustez do método ao ruído. Para isso, foram adicionadas às 75 imagens do conjunto de teste oito realizações diferentes de ruído branco gaussiano, para oito níveis diferentes de relação sinal-ruído (SNR). Na Figura 6 são mostrados os valores médios e desvios-padrão do conjunto de teste para cada um dos níveis de SNR avaliados.

Ao avaliar o comportamento do método desenvolvido quando adicionado ruído, percebeu-se que os valores médios dos erros de estimativa, para ambos os eixos, não se modificaram de maneira significativa, independente do nível de ruído aplicado. Os desvios-padrão dos erros de estimativa no eixo x também se mantiveram, mesmo com alteração do nível de ruído. Porém, os desvios-padrão dos erros de estimativa para as coordenadas do eixo $\boldsymbol{z}$ aumentaram conforme o aumento do nível de ruído. Essa diferença se deve à diferença da resolução em cada eixo da imagem. Um nível maior de ruído aumenta a incerteza na estimativa da posição do valor máximo da imagem. Assim, os posicionamentos no eixo z sofrem maior variabilidade devido à sua resolução ser muito maior do que a resolução do eixo x. Entretanto, os valores dos erros médios absolutos nas estimativas de posição foram menores que a dimensão de um pixel, sendo de 0,3031 mm no eixo x e de 7,1481  $\mu\mathrm{m}$ no eixo z.

#### 5. CONCLUSÃO

O objetivo principal deste trabalho foi o desenvolvimento de um método capaz de estimar a posição de defeitos em ENDs por ultrassom. O método proposto utiliza um modelo *autoencoder* e uma função de pós-processamento para compensar um desvio observado na localização das falhas em um dos eixos. Para que o objetivo principal do trabalho fosse atingido, foram definidas as etapas de: construção de um conjunto de dados, definição de uma arquitetura de DNN, treinamento e teste, e análise dos resultados.

Na obtenção de um conjunto de dados, fizeram-se simulações de 300 defeitos infinitesimais em diferentes posições com a ferramenta Field II. Esse conjunto de dados é usado nas etapas de treinamento e teste da DNN. Utilizouse um autoencoder com neurônios convolucionais, que é uma das topologias sugeridas na literatura para aplicações que buscam soluções de problemas inversos em imagens. A análise dos resultados obtidos pela aplicação do método proposto ao conjunto de testes mostrou que o método é eficaz ao estimar a localização de defeitos infinitesimais com erros na ordem de 0,3167 mm  $\pm$  0,4283 mm para o eixo horizontal, e 7,9720  $\mu$ m  $\pm$  5,0225  $\mu$ m para o eixo vertical. O método também é robusto ao ruído, mantendo o erro de estimativa das coordenadas em ambos os eixos, mesmo com a adição de ruído branco gaussiano, em vários níveis de intensidade, aos sinais de A-scan.

Para continuidade dos trabalhos, pretende-se aplicar a técnica de *Deep Learning* para a reconstrução de imagens de defeitos com geometrias mais complexas, em que os métodos analíticos, que usam aproximações para simplificar os modelos, não podem ser aplicados. Ainda, serão incluídos ao conjunto de dados, sinais A-scan provenientes de outras fontes, como de equipamentos reais de inspeção, para melhorar o modelo genérico aprendido pela rede.

# AGRADECIMENTOS

Os autores agradecem ao apoio financeiro da PETRO-BRAS/CENPES e CNPq (311726/2018-6). Este trabalho também foi realizado em parte com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), da Fundação Araucária (FA) e da Financiadora de Estudos e Projetos (FINEP).

# REFERÊNCIAS

- Arthur Chapon, P.B. (2019). Detection of flaws in close proximity using convolutional neural networks. 46th Annual Review of Progress in Quantitative Nondestructive Evaluation.
- Guarneri, G.A., Pipa, D.R., Neves, F., and de Arruda, L.V.R. (2017). A blind deconvolution approach to discontinuity location and characterization in ultrasonic nondestructive testing. In 2017 25th European Signal Processing Conference (EUSIPCO), 2496–2500.
- Guarneri, G.A., Pipa, D.R., Junior, F.N., de Arruda, L.V.R., and Zibetti, M.V.W. (2015). A sparse reconstruction algorithm for ultrasonic images in nondestructive testing. *Sensors*, 15(4), 9324–9343.
- Hellier, C. (2003). Handbook of Nondestructive Evaluation. McGraw-Hill handbooks. Mcgraw-hill, New York, NY, USA.
- Holmes, C., Drinkwater, B.W., and Wilcox, P.D. (2005).
  Post-processing of the full matrix of ultrasonic transmitreceive array data for non-destructive evaluation. NDT & E International, 38(8), 701–711. doi:10.1016/j. ndteint.2005.04.002.
- Jensen, J. (2004). Simulation of advanced ultrasound systems using field ii. In *Biomedical Imaging: Nano to Macro, 2004. IEEE International Symposium on*, 636– 639 Vol. 1. doi:10.1109/ISBI.2004.1398618.
- Jin, K.H., McCann, M.T., Froustey, E., and Unser, M. (2017). Deep convolutional neural network for inverse problems in imaging. *IEEE Transactions on Image Processing*, 26(9), 4509–4522.
- Keras (2020). Keras API reference. https://keras.io/ api/. Online; accessed 05 May 2020.
- Kino, G.S. (1987). Acoustic waves: devices, imaging, and analog signal processing, volume 107. Prentice-Hall Englewood Cliffs, NJ, Englewood Cliffs, NJ, USA.
- Lavarello, R., Kamalabadi, F., and O'Brien, W.D. (2006). A regularized inverse approach to ultrasonic pulse-echo imaging. *IEEE Transactions on Medical Imaging*, 25(6), 712–722.
- Luchies, A.C. and Byram, B.C. (2018). Deep neural networks for ultrasound beamforming. *IEEE Transacti*ons on Medical Imaging, 37(9), 2010–2021.
- Mao, X.J., Shen, C., and Yang, Y. (2016). Image denoising using very deep fully convolutional encoder-decoder networks with symmetric skip connections. ArXiv, abs/1603.09056.
- McCann, M.T., Jin, K.H., and Unser, M. (2017). Convolutional neural networks for inverse problems in imaging: A review. *IEEE Signal Processing Magazine*, 34(6), 85– 95.
- Mousavi, A., Patel, A.B., and Baraniuk, R.G. (2015). A deep learning approach to structured signal recovery. In 2015 53rd Annual Allerton Conference on Communication, Control, and Computing (Allerton), 1336–1343.
- Passarin, T.A.R., Wüst Zibetti, M., and Pipa, D.R. (2018). Sparse ultrasound imaging via manifold low-rank approximation and non-convex greedy pursuit. *Sensors*, 18(12), 4097.

- Prine, D. (1972). Synthetic aperture ultrasonic imaging. In Proceedings of the engineering applications of holography symposium, volume 287.
- Schmerr, L.W. (1998). Fundamentals of ultrasonic nondestructive evaluation: a modeling approach. New York, NY, USA.
- Stepanishen, P.R. (1971a). The time-dependent force and radiation impedance on a piston in a rigid infinite planar baffle. The Journal of the Acoustical Society of America, 49(3B), 841–849. doi:10.1121/1.1912424. URL https://doi.org/10.1121/1.1912424.
- Stepanishen, P.R. (1971b). Transient radiation from pistons in an infinite planar baffle. The Journal of the Acoustical Society of America, 49(5B), 1629–1638. doi: 10.1121/1.1912541. URL https://doi.org/10.1121/ 1.1912541.
- Thompson, R.B. and Thompson, D.O. (1985). Ultrasonics in nondestructive evaluation. *Proceedings of the IEEE*, 73(12), 1716–1755. ISSN 0018-9219.
- Tupholme, G.E. (1969). Generation of acoustic pulses by baffled plane pistons. *Mathematika*, 16(2), 209–224. doi: 10.1112/S0025579300008184.
- von Bernus, L., Mohr, F., and Schmeidl, T. (1993). Sizing and characterization of ultrasonic indications using imaging techniques. *Nuclear engineering and design*, 144(1), 177–198. doi:10.1016/0029-5493(93)90019-6.
- Voulodimos, A., Doulamis, N., Doulamis, A., and Protopapadakis, E. (2018). Deep learning for computer vision: A brief review. *Computational Intelligence and Neuroscience*, 2018, 7068349. doi:10.1155/2018/7068349. URL https://doi.org/10.1155/2018/7068349.
- Zeng, K., Yu, J., Wang, R., Li, C., and Tao, D. (2017). Coupled deep autoencoder for single image superresolution. *IEEE Transactions on Cybernetics*, 47(1), 27–37.