

Classificação do tempo de tratamento térmico em Aço SAF 2507 após Tratamento Térmico Utilizando SVM

João Carlos Simões Queiroz
Programa de Pós Graduação em
Mecatrônica (PPGM)
Universidade Federal da Bahia
(UFBA)
Salvador, Brasil
joaojcsq@gmail.com

Ivan Costa da Silva
Labind/Gpend (IFBA)
Instituto Federal da Bahia
(IFBA)
Salvador, Brasil
ivanslv@gmail.com

Eduardo Furtado Simas Filho
Programa de Pós Graduação em
Engenharias Elétrica e de
Computação (PPGEEC)
Universidade Federal da Bahia
(UFBA)
Salvador, Brasil
eduardo.simas@ufba.br

Ângelo Márcio Oliveira
Sant'Anna
Programa de Pós Graduação em
Mecatrônica (PPGM)
Universidade Federal da Bahia
(UFBA)
Salvador, Brasil
angelo.santanna@ufba.br

Abstract— O aço inoxidável Superduplex SAF 2507 é amplamente utilizado em ambientes agressivos devido à sua alta resistência à corrosão e à tração. Sua microestrutura é influenciada pelas variações térmicas que podem induzir alterações que afetam o desempenho mecânico do material. A avaliação não destrutiva da microestrutura é essencial para garantir a qualidade e confiabilidade do aço. O ensaio por ultrassom promete ser uma solução, pois existe variação do sinal ultrassônico no domínio da frequência produzidas por mudanças na microestrutura. Este estudo propõe a implementação de uma máquina de vetor de suporte (SVM) para classificar a microestrutura do aço SAF 2507 após tratamento térmico a 900°C, utilizando características dos sinais de ultrassom no domínio da frequência como entradas. Foram coletados 950 sinais de ultrassom em corpos de prova de aço SAF 2507 submetidos a tratamento térmico a 900°C por diferentes tempos. Os sinais de ultrassom foram pré-processados para janelar a região de interesse e obter as características do sinal no domínio da frequência. Um algoritmo SVM foi treinado com os dados pré-processados para classificar a microestrutura em diferentes tempos de tratamento térmico. Também foi utilizado um modelo de regressão logística para comparar os resultados com o SVM. O desempenho do SVM foi avaliado utilizando métricas de precisão e o resultado da regressão logística. A SVM apresentou alto desempenho na classificação da microestrutura do aço SAF 2507, com acurácia global de 97.72%, contra 94.05% do modelo linear. Os resultados indicam que a SVM é uma ferramenta promissora para avaliação não destrutiva da microestrutura em aços superduplex.

Keywords — Aço SAF 2507, Tratamento térmico, Microestrutura, Ultrassom, Máquina de suporte vetorial (SVM), Ensaio não destrutivo.

I. INTRODUÇÃO

Aços inoxidáveis superduplex (SDSS), com sua microestrutura bifásica constituída por ferrita (α) e austenita (γ) em proporções semelhantes, apresentam excelente desempenho em condições operacionais severas [1], [2]. A combinação de alta resistência à corrosão, incluindo a resistência à corrosão sob tensão, e elevada resistência mecânica torna os SDSS materiais estratégicos para aplicações em ambientes altamente corrosivos e sob altas cargas, superando os aços inoxidáveis austeníticos em diversas situações [3], [4]. Este aço apresenta excelente resistência à corrosão, tornando-o ideal para aplicações em ambientes altamente corrosivos onde é exigida alta performance [5], [6], [7].

A faixa de processamento e aplicação do SDSS é limitada à temperatura entre 300°C e 1000°C [8], devido à formação de fases prejudiciais (σ , χ , austenita secundária, R, ferrita rica em Cr, nitretos, carbonetos e G) [9], [10]. A precipitação de fases, enriquecidas principalmente em Cr, Mo ou N, promove a diminuição da resistência à corrosão localmente aos precipitados, favorecendo ataques corrosivos e reduzindo significativamente as propriedades mecânica [11].

O SDSS 2507 é a terceira geração de SDSS, com aproximadamente 25% Cr, 7% Ni e 4% Mo [12]. Este aço, ao ser submetido a um tratamento térmico, experimenta uma complexa transformação microestrutural. Estas modificações influenciam a morfologia, o refino do grão e a quantidade relativa do teor de austenita/ferrite na microestrutura [13]. A solidificação do aço ocorre na forma ferrítica, com posterior transformação parcial em austenita por meio de uma reação no estado sólido, a uma temperatura inferior. A fração volumétrica de austenita e ferrita na microestrutura final depende de diversos fatores, como a composição química, a taxa de resfriamento e a temperatura de tratamento [14].

A influência do envelhecimento sobre a nucleação e o crescimento de precipitados, o comportamento corrosivo e as propriedades mecânicas de aços inoxidáveis superduplex tem sido amplamente investigada na literatura [15], [16]. Estudos mais recentes exploraram outros aspectos, como o efeito do acabamento superficial na cinética de precipitação da fase σ [17] e a influência dessa fase nas propriedades mecânicas [18]. No entanto, a morfologia da fase σ e seu impacto nas propriedades dos materiais submetidos a diferentes temperaturas de envelhecimento ainda carecem de estudos mais aprofundados.

Uma maneira de realizar a verificação da mudança da morfologia é por meio da técnica de ultrassom que utiliza a propagação de ondas sonoras de alta frequência (acima de 20 kHz) através do material a ser inspecionado. Essas ondas são geradas por um transdutor e propagam-se pelo material, sendo refletidas por descontinuidades ou interfaces entre diferentes materiais. As ondas refletidas são captadas pelo mesmo transdutor ou por outro, e a partir da análise do tempo que a onda levou para propagar e retornar, e da amplitude do sinal recebido, é possível determinar a localização e o tipo de descontinuidade presente no material [19]. No espectro de frequência da onda sônica é possível detectar variações na microestrutura do material, o que proporciona uma análise das variações das propriedades da peça inspecionada [20].

Contudo o sinal ultrassônico no espectro de frequência é difícil de analisar visualmente [21]. Para auxiliar na detecção, algoritmos de aprendizagem de máquina podem ser utilizados para classificar diferentes níveis de tratamento térmico realizado no material inspecionado [22].

Neste estudo, é proposto a utilização de Máquinas de Vetores de Suporte (SVMs) para a classificação automatizada de classes de aços SAF 2507 após tratamento térmico. SVMs são algoritmos de aprendizado supervisionado que identificam um hiperplano ótimo para separar dados em classes distintas, maximizando a margem entre os vetores de suporte [23], [24]. Essa abordagem permite a classificação precisa de novos dados, otimizando o processo de caracterização metalúrgica [25], [26]. Essa abordagem oferece maior flexibilidade, permitindo que as empresas criem soluções sob medida para o controle da qualidade da produção dos SDSS.

II. METODOLOGIA

A. Corpos de prova (CP's)

Foram utilizadas 8 amostras de SAF 2507 (composição química na Tabela I), com dimensões de 34,4 mm de comprimento, 36,4 mm de largura e 10,8 mm de espessura com envelhecimento térmico a 900°C com tempos, em minutos, de 0, 15, 30, 45, 60, 90, 120 e 180.

TABLE I. COMPÓSIÇÃO QUÍMICA DO SAF 2507

Composição química (nominal) %								
C	Si	Mn	P	S	Cr	Ni	Mo	Outros
≤0,03	≤0,8	≤1,2	≤0,025	≤0,015	25	7	4	N = 0,3

B. Aquisição de sinais

Os sinais foram coletados utilizando um transdutor ultrassônico de imersão de 5 MHz e campo próximo de 80 mm. Para isso foi desenvolvido um *bubbler* de acoplamento para poder utilizar o equipamento fora da imersão na água. O *bubbler* é um cilindro com 90 mm de altura e 30 mm de diâmetro. O meio de transmissão da onda sônica foi água e a membrana para retenção da água foi uma camada de 0,3 mm de borracha de nitrílica. A Figura 1 apresenta o esquema do *bubbler* utilizado.




Fig. 1. Esquema do Bubbler.

Foram capturados 950 sinais em cada corpo de prova, totalizando 7600 sinais de forma de onda completa, como apresentado na Figura 2. Na mesma figura, é mostrada uma parte do sinal, janelado no segundo eco de retorno que apresenta mais informações da microestrutura do material.

Este intervalo janelado dos sinais medidos será utilizado nas análises.






Fig. 2. Sinal ultrassônico de onda completa

A Figura 3 (a) mostra as médias dos sinais capturados para cada corpo de prova (CPs), é possível observar que no domínio do tempo não é possível encontrar um padrão para classificar os CPs. No domínio da frequência, Figura 3 (b), também não é possível identificar um padrão de classificação.



(a)



(b)

Fig. 3. Média dos sinais capturados para diferentes tempos de envelhecimento térmico. (a) Domínio do tempo. (b) Domínio da frequência.

Para quantificar a variabilidade dos sinais coletados em cada amostra, calculou-se o desvio padrão. A Figura 4 apresenta os valores médios de cada amostra no domínio do tempo, com a região sombreada em vermelho representando a dispersão dos dados por meio do desvio padrão. Observa-se

que as amostras de 60 e 180 minutos exibiram maior variabilidade, o que pode sugerir um aumento na anisotropia do material nesses intervalos.

Na Figura 5, são mostrados os mesmos parâmetros estatísticos (média e desvio padrão), porém analisados no domínio da frequência. Notou-se maior dispersão dos dados nas amostras de 60, 90 e 120 minutos, particularmente em frequências inferiores a 4 MHz e superiores a 10 MHz. Para a amostra de 180 minutos, a variação foi menos pronunciada na faixa de 6 a 8 MHz.




Fig. 4. Média dos sinais com desvio padrão

A partir do sinal do domínio da frequência foram extraídos três parâmetros, o primeiro foi o valor do pico que indica a intensidade que determinada frequência atua no sinal; o segundo foi a frequência central que determina se houve variação no eixo da frequência nominal; o terceiro foi a largura a meia altura para estudar a variação na largura de banda do sinal. Todos os parâmetros foram normalizados entre 0 e 1 para manter a mesma escala.

A SVM foi treinada utilizando como entradas os três atributos citados. O algoritmo foi desenvolvido utilizando Python (versão 3.10.12) e a biblioteca “Scikit-learn” (versão 1.3.2). Para determinar o kernel e o parâmetro de regularização (C) foi utilizada a ferramenta GridSearchCV que realiza uma busca da melhor configuração para o modelo SVM, maximizando o desempenho com os dados fornecidos. Foram testados os kernels: *Radial Basis Function* (RBF), *polynomial* de grau 2 e *sigmoid* e os parâmetros de regularização: 0.1, 1, 10 e 1000. Foi utilizado uma *k-fold cross-validation* de 5 subconjuntos. Para o treinamento foi utilizado reprodutibilidade de 42 e 20% dos dados foram utilizados para o teste.





Fig. 5. Média da FFT sinais com desvio padrão.

Para o modelo de regressão logística, foi utilizado o otimizador L-BFGS com o máximo de 1000 iterações e *cross-validation* de 5.

III. RESULTADOS

A Figura 6 apresenta os parâmetros que foram extraídos da FFT. Na Figura 6 (a) é possível observar a variação dos valores de pico máximo de sinal. Na Figura 6 (b) são apresentados os valores da frequência central de cada amostra, onde é possível observar que não houve uma grande variação, os valores, salvo em 6 amostras, eram 0,8 ou 1. Isso ocorreu por conta da baixa resolução do equipamento utilizado para captura. O mesmo ocorreu em (c), onde são apresentados os valores medidos para a largura de banda.



(a)




Fig. 6. (a) Pico. (b) Frequência central. (c) Largura de banda.

A Tabela II mostra os resultados de acurácia média e desvio padrão para as interações do *cross-validation*. O kernel escolhido foi o *polynomial* e o parâmetro de regularização foi o valor de 1000, pois apresentou uma acurácia média de 97,47 % com desvio padrão de 2,64 %.

TABLE II. VALORES DE ACURÁCIA MÉDIA E DESVIO PADRÃO PARA 5 INTERAÇÕES. (VALORES EM PORCENTAGEM)

Kernel	C = 0.1	C = 1.0	C = 10.0	C = 1000.0
RBF	91,01 ± 4,79	94,71 ± 3,40	96,80 ± 3,11	95,95 ± 3,03
<i>polynomial</i>	88,64 ± 2,17	94,76 ± 3,36	95,99 ± 3,32	97,49 ± 2,64
<i>sigmoid</i>	82,79 ± 4,07	90,74 ± 4,03	90,54 ± 5,28	86,05 ± 3,42

Com os sinais coletados e pré-processados, a SVM foi treinada e os índices de precisão, recall, f1-score, suporte, acurácia, curva ROC e valor de AUC foram analisados para determinar a qualidade do resultado. A precisão mede a capacidade do modelo de prever corretamente a classe positiva quando realmente prevê positivo. Em outras palavras, quantas vezes o modelo acertou. O recall mede a capacidade do modelo de identificar todos os exemplos positivos. Ou seja, quantas vezes o modelo conseguiu encontrar todos os casos positivos. O F1-score é a média harmônica da precisão e recall, proporcionando uma medida balanceada do

desempenho do modelo. O suporte é o número de ocorrências de cada classe no conjunto de dados verdadeiro. A Tabela II apresenta os valores de precisão, recall, F1-score e suporte para cada classe de classificação do conjunto de teste. As classes de tempo de 60 e 180 minutos foram os que apresentaram o F1-score mais baixo, o que indica uma dificuldade do modelo em conseguir separar das demais classes. Essa dificuldade já era prevista na Figura 5, que mostrou a variação destes dados.

TABLE III. MÉTRICAS PARA CADA CLASSE DO CONJUNTO DE TESTE

Métricas para cada classe de classificação				
Classe	Precisão	Recall	F1-Score	Suporte
0 min	0,996 ± 0,005	0,999 ± 0,002	0,998 ± 0,003	190
15 min	0,937 ± 0,014	1,000 ± 0,000	0,967 ± 0,008	190
30 min	0,997 ± 0,003	0,999 ± 0,002	0,998 ± 0,001	190
45 min	1,000 ± 0,000	1,000 ± 0,000	1,000 ± 0,000	190
60 min	0,891 ± 0,0144	0,949 ± 0,007	0,919 ± 0,008	190
90 min	0,999 ± 0,0023	0,998 ± 0,003	0,998 ± 0,001	190
120 min	1,000 ± 0,000	1,000 ± 0,000	1,000 ± 0,000	190
180 min	0,998 ± 0,003	0,862 ± 0,019	0,925 ± 0,012	190

Como ilustrado na Figura 7, são apresentadas as curvas ROC e os respectivos valores de AUC para cada classe analisada. Observa-se que as amostras correspondentes a 15, 60 e 180 minutos não alcançaram o valor máximo de AUC (1,0), indicando que o modelo apresentou certa dificuldade na classificação desses sinais, com ocorrência de falsos positivos ou falsos negativos. Esta confusão também foi observada no F1-Score da Tabela II.




Fig. 7. Curvas ROC e valores de AUC.

A Figura 8 apresenta a matriz de confusão dos dados, a classe que teve o pior desempenho foi a de 180 minutos, 11,6% dos sinais que pertenciam a classe de 180 minutos foram confundidos com a classe de 60 minutos. O que já era esperado por conta dos dados mostrados na Tabela II. E na classe de 60 minutos, o algoritmo confundiu 5,9% dos sinais com a classe de 15 minutos. O restante dos dados o

classificador conseguiu separar em 100%. A acurácia global do classificador foi de 97,72%.




Fig. 8. Matriz de confusão do modelo SVM. Valores em porcentagem.

A Tabela III apresenta os valores de precisão, recall, F1-score e suporte para cada classe de classificação do conjunto de teste utilizando o modelo de regressão logística. Os resultados do F1-score foram, em sua maioria, menores que os atingidos no modelo SVM. Novamente as classes com tempo de 60 e 180 minutos foram os que apresentaram o F1-score mais baixo, o que reforça a dificuldade do modelo em conseguir separar das demais classes. A acurácia média global foi de $94,05 \pm 0,4\%$.

TABLE IV. MÉTRICAS PARA CADA CLASSE DO CONJUNTO DE TESTE

Métricas para cada classe de classificação				
Classe	Precisão	Recall	F1-Score	Suporte
0 min	0,915 ± 0,0183	1,000 ± 0,000	0,955 ± 0,010	190
15 min	0,853 ± 0,0201	1,000 ± 0,000	0,921 ± 0,012	190
30 min	0,919 ± 0,0087	1,000 ± 0,0000	0,958 ± 0,005	190
45 min	0,991 ± 0,0085	1,000 ± 0,000	0,995 ± 0,004	190
60 min	0,883 ± 0,0125	0,840 ± 0,028	0,861 ± 0,012	190
90 min	1,0000 ± 0,0000	0,913 ± 0,010	0,954 ± 0,006	190
120 min	1,0000 ± 0,0000	1,000 ± 0,000	1,000 ± 0,000	190
180 min	0,999 ± 0,0030	0,772 ± 0,024	0,870 ± 0,016	190

A Figura 9 apresenta a matriz de confusão dos dados, semelhante ao modelo SVM, as classes que tiveram piores desempenho foram as de 60 e 180 minutos. Contudo o modelo linear não conseguiu classificar corretamente a classe de 90 minuto, confundindo 5,5% com a classe de 30 minutos.

Os resultados obtidos neste estudo de discriminação das oito classes do aço inoxidável superduplex SAF 2507 que sofreram tratamento térmico por tempos diferentes, demonstram que o modelo SVM superou a Regressão Logística em termos de desempenho geral, alcançando uma acurácia de 97,75% contra 94,05% da Regressão Logística, além de apresentar um F1-score mais elevado. A análise das matrizes de confusão revelou que ambos os modelos

cometeram erros semelhantes na classificação, contudo o modelo linear confundiu uma classe a mais que o SVM.




Fig. 9, Matriz de confusão do modelo linear, Valores em porcentagem,

IV. CONCLUSÃO

A realização de análises metalográficas complementares poderia elucidar as similaridades microestruturais subjacentes que contribuem para essa confusão classificatória, além de validar quantitativamente os resultados obtidos pelo modelo.

Como perspectivas futuras, recomenda-se: (i) a aquisição de novos conjuntos de dados experimentais, (ii) a realização de caracterizações metalográficas mais abrangentes, e (iii) o estabelecimento de correlações quantitativas entre os parâmetros microestruturais e as *features* utilizadas pelo modelo. Esta abordagem permitiria tanto o aprimoramento do classificador quanto uma melhor compreensão das relações entre as propriedades do material e os sinais de ultrassom. Em trabalhos futuros serão exploradas técnicas de aprendizagem profunda.

AGRADECIMENTOS

Agradecimento ao Labind/GPEND (Instituto Federal da Bahia) pela disponibilização dos corpos de prova e ao CNPq pelo apoio financeiro.

REFERENCES

[1] C, Gennari, L, Pezzato, E, Piva, R, Gobbo, and I, Calliari, "Influence of small amount and different morphology of secondary phases on impact toughness of UNS S32205 Duplex Stainless Steel," *Mater, Sci, Eng, A*, vol, 729, pp, 149–156, 2018, doi: <https://doi.org/10.1016/j.msea.2018.05.063>,

[2] A, K, Maurya, C, Pandey, and R, Chhibber, "Dissimilar welding of duplex stainless steel with Ni alloys: A review," *Int, J, Press, Vessel, Pip*, vol, 192, p, 104439, 2021, doi: <https://doi.org/10.1016/j.ijpvp.2021.104439>,

[3] D, Panigrahi, S, Rout, and S, K, Patel, "Chemically accelerated laser processing of SDSS-2507 uniquely under in-situ prepared environments: A comparative study on material dissolution behavior and surface characteristics," *Opt, Laser Technol*, vol, 179, p, 111379, 2024, doi: <https://doi.org/10.1016/j.optlastec.2024.111379>,

[4] D, A, Ahmed and M, M, Mulapeer, "Differentiation

- of specific wear rates of AISI 304 austenitic and AISI 2205 duplex stainless steels at room and high temperatures,” *Heliyon*, vol, 8, no, 11, p, e11807, 2022, doi: <https://doi.org/10.1016/j.heliyon.2022.e11807>,
- [5] J.-O. Nilsson, “Super duplex stainless steels,” *Mater. Sci. Technol.*, vol, 8, no, 8, pp, 685–700, 1992, doi: 10.1179/mst.1992.8.8.685,
 - [6] D. Zhang, A. Liu, B. Yin, and P. Wen, “Additive manufacturing of duplex stainless steels - A critical review,” *J. Manuf. Process.*, vol, 73, pp, 496–517, 2022, doi: <https://doi.org/10.1016/j.jmapro.2021.11.036>,
 - [7] K. Devendranath Ramkumar *et al.*, “Effect of optimal weld parameters in the microstructure and mechanical properties of autogeneous gas tungsten arc weldments of super-duplex stainless steel UNS S32750,” *Mater. Des.*, vol, 66, pp, 356–365, 2015, doi: <https://doi.org/10.1016/j.matdes.2014.10.084>,
 - [8] V. van der Mee, “Welding of (super) duplex stainless steels,” *Biul. Inst. Spaw.*, no, 5, 2016,
 - [9] L. Karavias, L. Gargalis, J. S. Graff, M. Johansen, S. Diplas, and E. K. Karaxi, “Tensile Properties and Fracture Analysis of Duplex (2205) and Super Duplex (2507) Stainless Steels, Produced via Laser Powder Bed Fusion Additive Manufacturing,” *Metals (Basel)*, vol, 14, no, 7, 2024, doi: 10.3390/met14070838,
 - [10] V. Di Cocco, F. Iacoviello, and G. Ischia, “Duplex stainless steels ‘475°C embrittlement’: influence of the chemical composition on the fatigue crack propagation,” *Procedia Struct. Integr.*, vol, 3, pp, 299–307, 2017, doi: <https://doi.org/10.1016/j.prostr.2017.04.051>,
 - [11] Y. Fan, T. G. Liu, L. Xin, Y. M. Han, Y. H. Lu, and T. Shoji, “Thermal aging behaviors of duplex stainless steels used in nuclear power plant: A review,” *J. Nucl. Mater.*, vol, 544, p, 152693, 2021, doi: <https://doi.org/10.1016/j.jnucmat.2020.152693>,
 - [12] M. Koukolíková, P. Podaný, S. Rzepa, M. Brázda, and A. Kocijan, “Additive manufacturing multi-material components of SAF 2507 duplex steel and 15-5 PH martensitic stainless steel,” *J. Manuf. Process.*, vol, 102, pp, 330–339, 2023, doi: <https://doi.org/10.1016/j.jmapro.2023.07.057>,
 - [13] J. Dib *et al.*, “Improved tribological behaviour of super duplex stainless steel through plasma nitriding at ultra-low temperature without prior polishing,” *Surf. Coatings Technol.*, vol, 483, p, 130806, 2024, doi: <https://doi.org/10.1016/j.surfcoat.2024.130806>,
 - [14] M. Toozandehjani, K. A. Matori, F. Ostovan, F. Mustapha, N. I. Zahari, and A. Oskoueian, “On the correlation between microstructural evolution and ultrasonic properties: a review,” *J. Mater. Sci.*, vol, 50, no, 7, pp, 2643–2665, 2015, doi: 10.1007/s10853-015-8855-x,
 - [15] A. Gregori and J.-O. Nilsson, “Decomposition of ferrite in commercial superduplex stainless steel weld metals; microstructural transformations above 700 {textdegree}C,” *Metall. Mater. Trans. A*, vol, 33, no, 4, pp, 1009–1018, 2002, doi: 10.1007/s11661-002-0202-6,
 - [16] K. Nishimoto, K. Saida, and O. Katsuyama, “Prediction of Sigma Phase Precipitation in Super Duplex Stainless Steel Weldments,” *Weld. World*, vol, 50, no, 3, pp, 13–28, 2006, doi: 10.1007/BF03263429,
 - [17] M. A. E. Jepson, M. Rowlett, and R. L. Higginson, “The Effect of Surface Preparation on the Precipitation of Sigma During High Temperature Exposure of S32205 Duplex Stainless Steel,” *Metall. Mater. Trans. A*, vol, 48, no, 3, pp, 1491–1500, 2017, doi: 10.1007/s11661-016-3914-8,
 - [18] J. Wan, H. Ruan, J. Wang, and S. Shi, “The Kinetic diagram of sigma phase and its precipitation hardening effect on 15Cr-2Ni duplex stainless steel,” *Mater. Sci. Eng. A*, vol, 711, pp, 571–578, 2018, doi: <https://doi.org/10.1016/j.msea.2017.11.079>,
 - [19] X. Xu *et al.*, “A systematic review of ultrasonic techniques for defects detection in construction and building materials,” *Measurement*, vol, 226, p, 114181, 2024, doi: <https://doi.org/10.1016/j.measurement.2024.114181>,
 - [20] X. He, X. Jiang, R. Mo, and J. Guo, “Research on Ultrasonic NDT of Wire to Terminal Joints: Comparison of Combinations of Various CNNs and Signal Processing Technologies,” *J. Nondestruct. Eval.*, vol, 43, no, 3, p, 82, 2024, doi: 10.1007/s10921-024-01094-5,
 - [21] C. Li, L. Wang, L. Sun, Z. Chu, W. Liu, and J. Tao, “High Precision Ultrasonic Testing Method for Density of Engineering Plastics,” *Russ. J. Nondestruct. Test.*, vol, 60, no, 3, pp, 280–292, 2024, doi: 10.1134/S1061830924600011,
 - [22] S. Zamen, E. Dehghan-Niri, H. Al-Beer, J. Lindahl, and A. A. Hassen, “Characterization of nonlinear ultrasonic waves behavior while interacting with poor interlayer bonds in large-scale additive manufactured materials,” *NDT E Int.*, vol, 127, p, 102602, 2022, doi: <https://doi.org/10.1016/j.ndteint.2022.102602>,
 - [23] S. Sivaraman and N. Radhika, “Predictive analytics of wear performance in high entropy alloy coatings through machine learning,” *Phys. Scr.*, vol, 99, no, 7, p, 76014, Jun, 2024, doi: 10.1088/1402-4896/ad564c,
 - [24] Z. Xu *et al.*, “Terahertz Nondestructive Measurement of Heat Radiation Performance of Thermal Barrier Coatings Based on Hybrid Artificial Neural Network,” *Coatings*, vol, 14, no, 5, 2024, doi: 10.3390/coatings14050647,
 - [25] J. Gola *et al.*, “Objective microstructure classification by support vector machine (SVM) using a combination of morphological parameters and textural features for low carbon steels,” *Comput. Mater. Sci.*, vol, 160, pp, 186–196, 2019, doi: <https://doi.org/10.1016/j.commatsci.2019.01.006>,
 - [26] J.-G. Kim, C. Jang, and S.-S. Kang, “Classification of ultrasonic signals of thermally aged cast austenitic stainless steel (CASS) using machine learning (ML) models,” *Nucl. Eng. Technol.*, vol, 54, no, 4, pp, 1167–1174, 2022, doi: <https://doi.org/10.1016/j.net.2021.09.033>,