



Latin American Journal of Energy Research – Lajer (2025) v. 12, n. 3, p. 39–44
<https://doi.org/10.21712/lajer.2025.v12.n3.p39-44>

1º Encontro Interdisciplinar em Energia, Programa de Pós-graduação em Energia, Ufes



Uso de ferramentas de inteligência artificial para identificar polimorfos de CaCO₃ no processo de incrustação em condições de poços de petróleo *Use of artificial intelligence tools to identify CaCO₃ polymorphs in the scaling process under oil well conditions*

Ozeas dos Santos Silva Souza¹, Fabio de Assis Ressel Pereira², Wanderley Cardoso Celeste^{2,*}

¹ Aluno do Programa de Pós-Graduação em Energia, Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

² Professor do Programa de Pós-Graduação em Energia, Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

*Autor para correspondência, E-mail: ozeassantossilva@gmail.com

Resumo: A incrustação inorgânica por carbonato de cálcio (CaCO₃) em poços de petróleo é um dos principais desafios à garantia de escoamento, sobretudo em ambientes do Pré-sal, onde variações de pressão, temperatura e desgaseificação de CO₂ favorecem a precipitação de polimorfos como calcita, aragonita e vaterita. Esses depósitos reduzem a eficiência produtiva e elevam custos operacionais. Neste contexto, o presente trabalho propõe o uso de redes neurais artificiais (RNAs) e técnicas de visão computacional para a identificação e segmentação automatizada dos polimorfos de CaCO₃ a partir de imagens microscópicas “*in situ*”. O modelo foi desenvolvido com base na arquitetura YOLOv8n-seg, uma rede neural convolucional do tipo *You Only Look Once* (YOLO) de última geração, projetada para realizar detecção e segmentação de objetos em tempo real com elevada precisão e baixo custo computacional, adaptada neste estudo para identificar e quantificar morfologias cristalinas de CaCO₃. A rede neural foi treinada e testada com imagens obtidas em reator pressurizado sob condições simuladas de poços do Pré-sal. O desempenho do modelo foi avaliado por métricas de precisão (mAP@0.5 = 0,933) e F1-score (0,89), demonstrando alta acurácia na detecção e classificação dos cristais. Os resultados indicam que a abordagem de *Artificial Intelligence* (AI) permite distinguir morfologias de calcita, aragonita e vaterita com rapidez e confiabilidade, atuando de forma complementar aos métodos tradicionais de caracterização, como difração de raios X e microscopia eletrônica. O estudo evidencia o potencial das redes neurais na análise preditiva de incrustações, contribuindo para o desenvolvimento de estratégias de controle e mitigação em sistemas de produção de petróleo.

Palavras-chave: incrustação inorgânica; carbonato de cálcio; redes neurais; visão computacional; YOLOv8.

Abstract Inorganic scaling by calcium carbonate (CaCO₃) in oil wells is one of the major challenges to flow assurance, especially in pre-salt environments where variations in pressure, temperature, and CO₂ degassing promote the precipitation of polymorphs such as calcite, aragonite, and vaterite. These deposits reduce production efficiency and significantly increase operational costs. In this context, this study proposes the use of artificial neural networks (ANNs) and computer vision techniques to automatically identify and segment CaCO₃ polymorphs from *in situ* microscopic images. The model was developed using the YOLOv8n-seg architecture, a state-of-the-art *You Only Look Once* (YOLO) convolutional neural network designed for real-time object detection and segmentation with high accuracy and low computational cost, adapted here to identify and quantify CaCO₃ crystalline morphologies. The training, performed with images obtained in a pressurized reactor under simulated pre-salt well conditions, achieved expressive performance metrics (mAP@0.5 = 0.933 and F1-score = 0.89). The results demonstrate that

the Artificial Intelligence (AI) based approach can distinguish calcite, aragonite, and vaterite morphologies quickly and reliably, complementing traditional characterization methods such as X-ray diffraction and scanning electron microscopy, by enhancing automatic and real-time analytical capabilities. The study highlights the potential of neural networks to improve the diagnosis and control of scale formation in petroleum production systems, contributing to higher operational efficiency and safety.

Keywords: inorganic scaling; calcium carbonate; neural networks; computer vision; YOLOv8.

1 Introdução

O petróleo permanece como uma das principais fontes de energia mundial, representando cerca de 30% da matriz energética global de acordo com IEA (2024). No Brasil, a produção em reservatórios do Pré-sal responde por mais de 75% do total nacional (EPE, 2024), caracterizando-se por alta produtividade, teores significativos de CO₂ dissolvido (acima de 20% em volume) e águas de formação extremamente salinas (Angelo e Ferrari, 2024). Tais condições impõem desafios à Garantia de Escoamento (GARESC), especialmente no que se refere à incrustação inorgânica por CaCO₃, que causa obstruções em dutos, válvulas e equipamentos submarinos, comprometendo a eficiência produtiva e a integridade dos sistemas (Oliveira et al., 2019; Cosmo et al., 2023).

A desgaseificação do CO₂ é apontada como o principal fator responsável pela precipitação de CaCO₃ em condições de poço. Estudos de Cosmo et al. (2019) demonstraram que a liberação de CO₂ dissolvido pode responder por 60% a 90% da massa total de calcita precipitada. Essa perda de CO₂ reduz a solubilidade da calcita, eleva o pH e induz a nucleação dos polimorfos de CaCO₃: calcita, aragonita e vaterita, cada um apresentando propriedades físico-químicas distintas. A calcita é a fase mais estável, enquanto aragonita e vaterita são formas metaestáveis cuja formação depende fortemente de variáveis como temperatura, pressão, salinidade e razão gás/óleo (Angelo e Ferrari, 2024).

Os impactos operacionais e econômicos associados à incrustação são expressivos. Estima-se que até um terço das perdas globais de produção estejam relacionadas a esse fenômeno, com custos anuais superiores a 1,5 bilhão de dólares (Oliveira et al., 2019). Métodos convencionais de caracterização, como microscopia eletrônica de varredura (MEV), difração de raios X (DRX) e microfluorescência de raios X (μ XRF), permitem identificar os polimorfos formados, mas demandam longos tempos de análise e infraestrutura laboratorial complexa (Cosmo et al., 2023).

Com os avanços recentes em IA e visão computacional, surgem novas possibilidades para a análise automatizada e preditiva de fenômenos físico-químicos complexos. Trabalhos como os de Ferreira et al. (2022) e Paz et al. (2017) aplicaram RNAs em modelos de previsão de incrustação e solubilidade, enquanto Wang et al. (2024), Wang et al. (2025) e Casas et al. (2024) demonstraram a eficiência da arquitetura YOLOv8, uma rede neural convolucional voltada à detecção e segmentação de objetos em tempo real, aplicada com sucesso em análises de superfícies metálicas e análises médicas.

Diante desse cenário, este estudo propõe o uso de redes neurais artificiais baseadas na arquitetura YOLOv8 para a detecção, classificação e segmentação automática dos polimorfos de CaCO₃ em imagens microscópicas obtidas em condições simuladas de poços do Pré-sal. O objetivo é desenvolver um modelo capaz de complementar os métodos laboratoriais tradicionais, ampliando a capacidade de diagnóstico e contribuindo para estratégias mais eficazes de controle e mitigação de incrustações em sistemas de produção de petróleo.

2 Metodologia

O estudo adota uma abordagem experimental aliada à inteligência artificial, voltada à caracterização automatizada de polimorfos de CaCO₃ formados sob condições representativas de poços de petróleo do Pré-sal. O processo metodológico foi estruturado em três etapas principais: (i) construção e anotação do conjunto de dados de imagens, (ii) implementação e treinamento de rede neural e (iii) avaliação do desempenho da rede neural.

2.1 Construção e anotação do conjunto de dados

As imagens utilizadas correspondem a resultados de simulações de incrustações de CaCO₃ realizadas em diferentes cenários experimentais. Essas imagens foram obtidas no Laboratório de Simulação de Incrustações (Lavagante) da Universidade Federal do Espírito Santo (UFES), unidade de Vitória – ES. O conjunto de imagens foi redimensionado para o tamanho 640x640 pixels e realizou-se marcação e anotação

dos poliformos incrustados. A Figura 1, demonstra vários polimorfos (aragonita e calcita) com linhas traçadas em volta da área incrustada, fornecendo a identificação, localização e morfologia do polimorfo. O conjunto totalizou-se por 510 instâncias de imagens distribuídas entre quatro classes morfológicas: calcita, aragonita, vaterita esferulítica e vaterita dentrítica. O conjunto foi dividido em 80% para treinamento, 10% para validação e 10% para teste, assegurando representatividade e equilíbrio entre as classes.

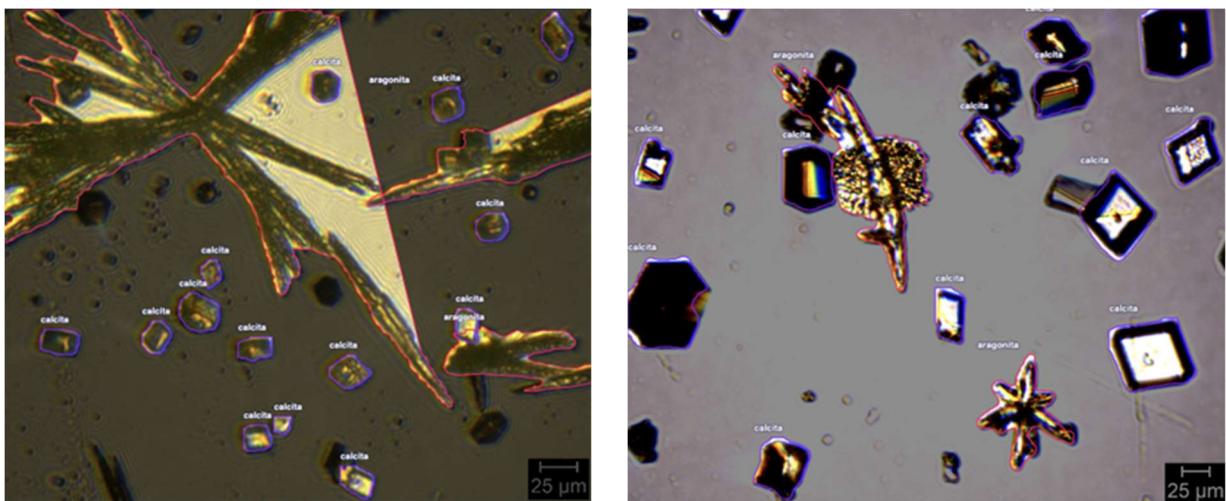


Figura 1. Anotação manual dos poliformos presentes na imagem.

2.2 Implementação e treinamento da rede neural

Entre os diferentes tipos de RNAs, as redes neurais convolucionais (CNNs) destacam-se por seu desempenho em tarefas de processamento de imagens, realizando automaticamente a extração hierárquica de características espaciais, como forma, textura e contorno, o que as torna amplamente aplicáveis em reconhecimento e classificação morfológica (Wang et al., 2024). Nesse contexto, a arquitetura YOLO representa um tipo base de CNN projetada para detecção e segmentação de objetos em tempo real, reconhecida pela alta precisão e baixo custo computacional (Casas et al., 2024).

Neste trabalho, empregou-se a variante YOLOv8n-seg, uma versão otimizada (nano-segmentação) com tamanho reduzido e eficiência computacional, que integra simultaneamente os processos de detecção de objetos e segmentação de instâncias. Essa configuração reduz o tempo de inferência e mantém alta taxa de acerto mesmo em conjuntos de dados reduzidos ou com variações de iluminação e textura (Wang et al., 2024; Wang et al., 2025). O modelo foi treinado utilizando técnicas de *data augmentation* (rotação, recorte e variação de brilho) que aumentam a quantidade de imagens no conjunto de treinamento e testes segundo recomendações de Wang et al. (2025).

2.3 Avaliação do desempenho da rede neural

A avaliação de modelos baseados em CNNs voltados à segmentação de imagens requer o uso de métricas quantitativas capazes de mensurar a precisão da detecção, a cobertura da segmentação e o equilíbrio entre acertos e erros. As principais métricas adotadas neste estudo incluem a precisão (*precision*), o revocação (*recall*), o *F1-score* e o *mean Average Precision* (mAP). A precisão indica a proporção de predições corretas entre todas as instâncias detectadas, enquanto o revocação mede a capacidade do modelo em identificar corretamente as instâncias presentes na imagem. O *F1-score* representa a média harmônica entre precisão e revocação equilibrando a avaliação entre falsos positivos e falsos negativos (Casas et al., 2024). A métrica mAP sintetiza o desempenho global do modelo em diferentes limiares de sobreposição entre a predição e a verdade de referência (*Intersection over Union* – IoU). A análise em múltiplos limiares, como mAP@0.5 e mAP@0.5:0.95, permite uma avaliação mais rigorosa da acurácia espacial e da consistência das segmentações (Casas et al., 2024; Wang et al., 2024).

Em aplicações de YOLOv8 voltadas à segmentação de fissuras em estruturas e detecção biomédica, Wang et al. (2024) e Wang et al. (2025) também adotaram essas métricas, demonstrando a robustez do modelo na análise de superfícies complexas e de imagens de baixa resolução. Esses autores destacaram o papel do *F1-score* como indicador-chave do equilíbrio entre precisão e revocação, e do mAP como métrica consolidada para comparação de arquiteturas de redes neurais voltadas à detecção e segmentação.

Assim, neste trabalho, o conjunto de métricas, alinhadas a trabalhos já validados, composto por *precision*, *recall*, *F1-score* e mAP foi adotado como base para a avaliação da arquitetura YOLOv8n-seg, permitindo uma análise quantitativa e comparável do desempenho da rede neural na identificação e segmentação dos polimorfos de CaCO₃.

3 Resultados e discussões

As métricas apresentadas na Tabela 1 demonstra a estabilidade e convergência do treinamento da rede neural com arquitetura YOLOv8n-seg nas últimas cinco épocas de treinamento e testes. Observa-se que os valores de precisão e revocação evoluíram de forma consistente, estabilizando-se em torno de 0,92 e 0,90, respectivamente, o que indica capacidade de generalização da rede neural na identificação dos polimorfos de CaCO₃.

Tabela 1. Métricas de avaliação da rede neural ao final do treinamento.

Época	Precisão	Revocação	mAP@0.5	mAP@0.5:0.95	Confiança Ótima
396	0.889	0.834	0.8999	0.6475	0.784
397	0.900	0.845	0.9059	0.6553	0.784
398	0.908	0.862	0.9110	0.6411	0.784
399	0.906	0.880	0.9154	0.6462	0.784
400	0.923	0.900	0.9268	0.6511	0.784

Na Figura 2, observa-se que o *F1-score* médio de 0,89, obtido a um nível ótimo de confiança de 0,784 (extraídos da relação da curva *F1-Confidence*), reflete o equilíbrio entre as taxas de falsos positivos e falsos negativos, configurando um desempenho robusto do modelo em diferentes condições de iluminação e textura das imagens. Essa métrica é coerente com os resultados reportados por Wang et al. (2024) e Wang et al. (2025), que também observaram estabilidade de *F1-score* superior a 0,85 em aplicações com arquitetura YOLOv8 para tarefas de segmentação.

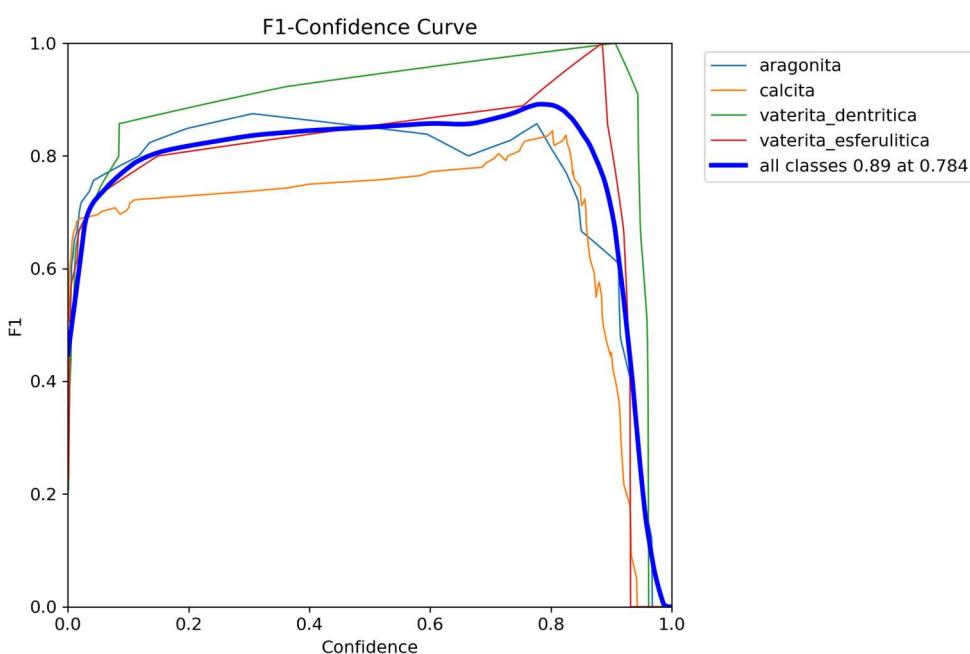


Figura 2. Curva de F1-score em função da confiança ótima para os polimorfos de CaCO₃.

A Figura 3 apresenta o resultado qualitativo da aplicação do modelo treinado sobre imagens não vistas durante o treinamento e testes, evidenciando a capacidade de generalização da rede neural. Observa-se que o modelo foi capaz de detectar, classificar e segmentar corretamente os diferentes polimorfos de CaCO₃ — vaterita (a), aragonita e calcita (b) e aglomerado de aragonita (c) — mesmo em condições de variação de textura, contraste e sobreposição de cristais. No item c da Figura 3, o modelo foi capaz de segmentar

corretamente toda a área incrustada pelo aglomerado de aragonita. No item b, o modelo detectou e segmentou diferentes poliformos presentes na mesma imagem, enquanto no item c, a rede neural identificou com precisão a existência de um único polimorfo, demonstrando assim, conhecimento das morfologias distintas de cada tipo. Essa resposta consistente em dados inéditos demonstra que o modelo não sofreu sobreajuste (*overfitting*), ou seja, apenas aprendeu a segmentar as imagens vistas e manteve alta precisão semântica e espacial ao identificar as fronteiras morfológicas de cada polimorfo.

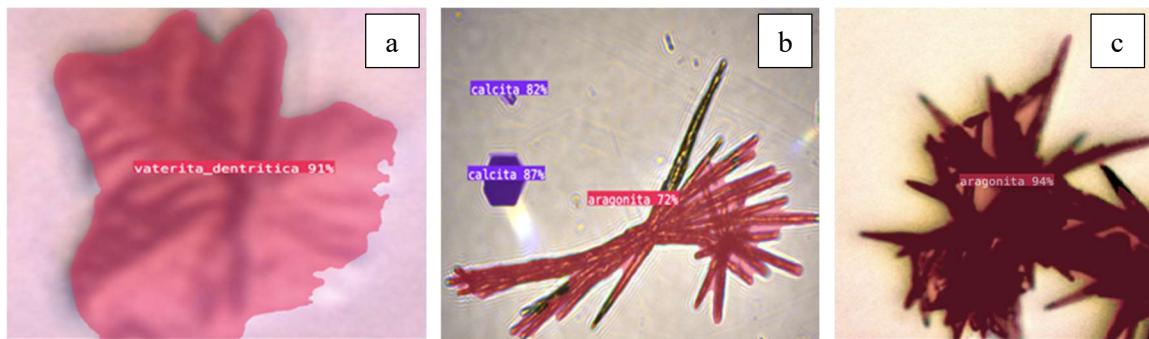


Figura 3. Detecção, classificação e segmentação de CaCO_3 (Vaterita, Aragonita e Calcita) pela rede neural treinada.

4 Conclusões

A aplicação de técnicas de inteligência artificial na análise de incrustações inorgânicas demonstrou potencial para ampliar a compreensão dos fenômenos de precipitação e morfologia dos polimorfos de CaCO_3 sob condições típicas de poços de petróleo. A utilização da arquitetura YOLOv8n-seg permitiu integrar a detecção e a segmentação de partículas em um único processo, reduzindo o tempo de análise e aumentando a precisão da caracterização morfológica. Os resultados indicam que modelos baseados em redes neurais convolucionais podem atuar de forma complementar aos métodos laboratoriais tradicionais, oferecendo suporte automatizado, rápido, quantitativo e qualitativo à pesquisa em garantia de escoamento e mitigação de incrustações. Destaca-se os principais avanços da pesquisa:

- O desenvolvimento de um modelo baseado na arquitetura YOLOv8n-seg mostrou-se eficaz na identificação e segmentação simultânea dos polimorfos de CaCO_3 (calcita, aragonita e vaterita), mesmo em imagens com sobreposição e variação de contraste, reforçando a capacidade da rede em reconhecer padrões visuais complexos.
- A metodologia proposta demonstrou equilíbrio entre precisão e revocação, atingindo um *F1-score* médio de 0,89 em nível ótimo de confiança (0,784), indicando a consistência do modelo e sua capacidade de generalização para diferentes condições experimentais.
- Em comparação com estudos anteriores, os resultados obtidos mantêm coerência com as aplicações industriais e médicas reportadas por Casas et al. (2024), Wang et al. (2024) e Wang et al. (2025), confirmando a eficácia da arquitetura YOLOv8 em contextos de inspeção visual e análise morfológica de materiais.
- A proposta metodológica consolida uma ponte entre experimentação e modelagem computacional, contribuindo para o avanço de soluções preditivas na área de incrustações minerais e garantia de escoamento, alinhadas às necessidades da indústria de petróleo e gás.

Agradecimentos

Os autores agradecem ao Laboratório de Incrustações Inorgânicas (Lavagante) da Universidade Federal do Espírito Santo (UFES), unidade de Vitória – ES, pela disponibilização das imagens experimentais utilizadas neste estudo e pelo suporte técnico durante o processo de coleta de dados. Agradecem-se também à Petrobras, pelo apoio financeiro concedido por meio de bolsa de estudos vinculada ao projeto de pesquisa: Modelagem e simulação da incrustação inorgânica em válvulas AICD em condições de poços petrolíferos.

Referências bibliográficas

- Angelo, JF de e Ferrari, JV (2024) ‘Study of calcium carbonate scaling on steel using a high salinity brine simulating a pre-salt produced water,’ *Geoenergy Science and Engineering*, 233, p.212541. <https://doi.org/10.1016/j.geoen.2023.212541>.

- Casas, E et al. (2024) ‘A comparative study of Yolov5 and yolov8 for corrosion segmentation tasks in metal surfaces,’ *Array*, 22, p. 100351. <https://doi.org/10.1016/j.array.2024.100351>.
- Cosmo, R de et al. (2019) ‘Estimating CO₂ degassing effect on CaCO₃ precipitation under oil well conditions’, *Journal of Petroleum Science and Engineering*, 181, p. 106207. <https://doi.org/10.1016/j.petrol.2019.106207>.
- Cosmo, R de et al. (2023) ‘CO₂ degassing in CaCO₃ precipitation in the presence of oil: Implications, modeling, Numerical Simulation, validation, prototype development, and experimental results’, *Geoenergy Science and Engineering*, 228, p. 211885. <https://doi.org/10.1016/j.geoen.2023.211885>.
- EPE (2024) *Balanço Energético Nacional 2024*, Empresa de Pesquisa Energética. <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2024> (accessed: 25 March 2025).
- Ferreira, BX et al. (2022) ‘Development of artificial neural network models for the simulation of a CaCO₃ scale formation process in the presence of monoethylene glycol (MEG) in dynamic tube blocking test equipment’, *Energy & Fuels*, 36(4), pp. 2288–2299. <https://doi.org/10.1021/acs.energyfuels.1c03364>.
- IEA (2024) *World energy outlook 2024 – analysis – IEA, World Energy Outlook 2024*. <https://www.iea.org/reports/world-energy-outlook-2024> (accessed: 02 April 2025).
- Oliveira, DF et al. (2019) ‘Characterization of scale deposition in oil pipelines through X-ray microfluorescence and X-ray microtomography’, *Applied Radiation and Isotopes*, 151, pp. 247–255. <https://doi.org/10.1016/j.apradiso.2019.06.019>.
- Oliveira, MCK de, Gonçalves, M de AL and Marques, LC do C (2018) *Fundamentos de garantia de escoamento*. 1st edn. Rio de Janeiro: Interciência.
- Paz, PA et al. (2017) ‘Prediction of calcium carbonate scaling in pipes using artificial neural networks’, *Volume 5A: Pipelines, Risers, and Subsea Systems* [Preprint]. <https://doi.org/10.1115/omae2017-61233>.
- Wang, H et al. (2025) ‘Yolo-HV: A fast yolov8-based method for measuring hemorrhage volumes’, *Biomedical Signal Processing and Control*, 100, p. 107131. doi:10.1016/j.bspc.2024.107131.
- Wang, R et al. (2024) ‘FDSC-Yolov8: Advancements in automated crack identification for enhanced safety in underground engineering’, *Computer Modeling in Engineering & Sciences*, 140(3), pp. 3035–3049. <https://doi.org/10.32604/cmes.2024.050806>.