

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

CARACTERIZAÇÃO DE CAVINGS UTILIZANDO TECNOLOGIA SAM EM AMOSTRAS DE CALHA

AUTORES:

Joab G. dos Santos 1, Luiz H. L. de Oliveira2, Gilvandro C. S. de Medeiros3, Lucas S. P. Sátiro4, Luiz H. L. Oliveira5, Leonardo C. de Montalvão6, Estefane O. do Nascimento7, Guilherme S. Frota8, Lícia V. Fernandes9, Rosiney A. Martins10

INSTITUIÇÃO:

Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN)¹ e Geowellex do Brasil Serviços Petrolíferos²

CARACTERIZAÇÃO DE CAVINGS UTILIZANDO TECNOLOGIA SAM EM AMOSTRAS DE CALHA

Resumo

Amostras de calhas representam fragmentos de rocha produzidos durante a perfuração de poço de petróleo. A variação em tamanho e formato desses fragmentos pode indicar problemas de estabilidade das paredes do poço, decorrentes de fatores geológicos ou de engenharia de poços, quando ocorre um tamanho excessivamente grande, denominado cavings. Neste cenário, este estudo visa caracterizar cavings por meio da análise de imagens de amostras de calha pertencentes ao acervo litológico da empresa Geowellex Drilling and Geology Automation (com sede em Macaíba/RN), utilizando Inteligência Artificial (IA). A metodologia adotada envolveu a aplicação de um modelo de segmentação de imagens, conhecido como Segment Anything Model (SAM), em uma fotografia de amostras de calha abrangendo diferentes tipos de rochas, com a presença de cavings. Após feita essa segmentação foi possível a atribuição de classes para cada um dos grãos de caving na amostra de calha. Com isso, pode-se aplicar o modelo de visão computacional YOLOv8 para detecção automática desses tipos. Os cavings presentes na amostra de calha são de folhelhos, margas e calcários, e possuem tamanhos variando de 1,0 cm até 4,0 cm (com média em torno dos 2,0 cm), bem como diferentes formatos, desde arredondados, até mais alongados e achatados, por vezes pontiagudos. Os resultados preliminares demonstram a viabilidade dos modelos SAM e YOLOv8 como ferramentas complementares na identificação e caracterização de cavings de forma mais ágil, contribuindo para aprimorar a segurança no processo de perfuração de poços de petróleo e gás.

Palavras-chave: Cavings, Inteligência Artificial, Segment Anything Model (SAM), Amostras de calha, Perfuração de poços

Abstract

Cutting samples represent rock fragments produced during the drilling of oil wells. The variation in size and shape of these fragments can indicate wellbore stability issues caused by geological or well engineering factors, especially when excessively large fragments, known as cavings, occur. In this context, this study aims to characterize cavings through image analysis of cuttings samples from the lithological collection of the company Geowellex Drilling and Geology Automation (based in Macaíba/RN), using Artificial Intelligence (AI). The methodology involved the application of an image segmentation model, known as the Segment Anything Model (SAM), to a photograph of cuttings samples encompassing different types of rocks, including the presence of cavings. After segmentation, it was possible to assign classes to each caving grain in the cuttings sample. Consequently, the YOLOv8 computer vision model was applied for automatic detection of these types. The cavings present in the cuttings sample consist of shales, marls, and limestones, ranging in size from 1.0 cm to 4.0 cm (with an average around 2.0 cm), and varying in shape, from rounded to more elongated and flattened, sometimes pointed. Preliminary results demonstrate the feasibility of the SAM and YOLOv8 models as complementary tools in the identification and characterization of cavings in a more agile manner, contributing to improved safety in the drilling process of oil and gas wells.

Keywords: Cavings, Artificial Intelligence, Segment Anything Model (SAM), Cuttings samples, Well drilling

Introdução

As amostras de calhas, são compostas por fragmentos de rochas que são gerados durante o processo de perfuração de poços de petróleo, esses são fundamentais para a compreensão da estabilidade das paredes dos poços. As variações no tamanho e formato desses fragmentos pode indicar problemas significativos de estabilidade, especialmente quando ocorre um aumento no volume dos fragmentos de maior tamanho, conhecidos como cavings. Neste cenário, o presente estudo tem como objetivo demonstrar uma metodologia para acelerar a caracterização de cavings através da análise de imagens de amostras de calha utilizando técnicas de Inteligência Artificial (IA).

Durante o processo de perfuração, são amostras de rochas em intervalos de amostragem pré-determinados para identificar os diversos tipos litológicos que aparecem durante a perfuração. Nesse contexto, a perfuração atravessa as camadas rochosas através da rotação e peso sob broca, resultando na formação de “cascalhos de perfuração” ou “amostras de calhas”. Normalmente, esses fragmentos têm tamanhos variados, indo desde submilimétricos até centimétricos, dependendo das condições de perfuração, do tipo de broca e das características da rocha.

No caso dos cavings, eles são provenientes de desabamentos das paredes do poço, não tendo sido perfurados pela broca. Por esse motivo, possuem tamanho muito maior do que os cascalhos triturados durante a perfuração. Durante o processo de desprendimento das paredes do poço, esses cavings misturam-se aos cascalhos triturados durante o processo de subida até a superfície, por meio do fluido de perfuração. Nesse sentido, os cavings são de interesse particular devido às suas implicações na estabilidade e operação do poço. A presença desses fragmentos pode indicar condições geológicas adversas, como instabilidade da formação, pressão de perfuração inadequada, bem como outros problemas decorrentes das operações de perfuração.

Ao chegar na superfície, esses fragmentos de rocha são separados do fluido por meio de processos de peneiramento utilizando peneiras vibratórias industriais. As amostras são então recolhidas na calha em frente às peneiras vibratórias e levadas para a cabine de mudlogging para análise pela equipe de geologia. Mesmo com os avanços tecnológicos, a caracterização dos cavings ainda se baseia principalmente na interpretação visual do geólogo no campo, o que pode levar um certo tempo para ser feito tendo em vista todo o processo de coleta das amostras, preparação e análise das mesmas.

Embora existam uma série de trabalhos visando a aplicação de métodos para melhorar os processos de análises no contexto da perfuração de poços de petróleo (LOERMANS et al., 2011; MARSALA et al., 2011a, 2011b; LOERMANS et al., 2012), a indústria do petróleo ainda carece de estudos voltados mais à análise de cavings e como tornar o processo de identificação e caracterização mais rápidos e assertivos. Um dos poucos trabalhos relacionados ao tema é o de Skea et al. (2018), por exemplo, que usa uma abordagem de processamento de imagens para caracterizar os tipos de cavings com base no arredondamento e esfericidade desses fragmentos de rocha. Segundo esse trabalho, os cavings podem possuir formatos variados, sendo os principais: “blocky”, quando os fragmentos de rocha possuem uma estrutura cúbica; “slipntery”, quando os fragmentos são achatados, finos e com estruturas planares; “tabular”, quando exibem fácies flanares; e, finalmente “angular”, quando possuem formatos triangulares. Nesse trabalho de Skea et al. (2018), no entanto, são utilizados softwares para processamento de imagens que fornecem apenas uma melhor visualização dos contornos dos grãos para posterior análises e interpretações humanas, não sendo um processo automatizado.


Metodologia

O presente trabalho foi iniciado a partir de pesquisas bibliográficas referentes aos temas “visão computacional”, “perfuração de poços de petróleo e gás natural” e “cavings” visando compreender tais temas e os principais métodos utilizados na indústria. A partir disso, foi possível que os pesquisadores estivessem aptos a realizar os testes e implementar os modelos de visão computacional propostos para identificar cavings a partir da análise de amostras de calhas de forma mais célere.

Este estudo adota uma abordagem sistemática para classificar os cascalhos de perfuração contendo cavings, a partir de amostras de calha do acervo da litoteca da Geowellex, sendo elas provenientes de poços de petróleo reais, de uma determinada bacia sedimentar. As descrições dos cavings foram feitas conforme descrito no manual "Real-time Wellbore Stability Analysis: An Observation from Cavings at Shale Shakers".

De maneira a facilitar a validação da metodologia, inicialmente, os cascalhos presentes na amostra de calha foram caracterizados pela equipe de geologia da empresa Geowellex quanto aos tipos litológicos, tamanho dos grãos e formatos, principalmente. Posteriormente, foram adquiridas imagens desses fragmentos de rocha sobre papel milimetrado (Figura 1) para facilitar a aplicação dos algoritmos de inteligência artificial.

Figura 1 –Fotografias dos fragmentos de rocha. A) Cuttings de folhelho, marga e calcário; B) Cavings de folhelho, marga e calcário. Notar diferença de tamanho entre os fragmentos nas duas imagens.




Fonte: elaboração própria.

Por meio da plataforma web Roboflow (disponível em: <https://roboflow.com/>), foi iniciado um projeto com as imagens da amostra de calha contendo os cavings. De maneira a poder segmentar cada um dos grãos, utilizou-se a ferramenta “smart polygon” que detecta automaticamente, por meio do SAM, os limites dos objetos selecionados. A cada definição dos limites dos grãos de cavings foram definidas também as classes (labels) as quais pertencem cada um dos grãos, podendo ser: “blocky”, “splintery”, “angular” e “tabular”, que são os formatos possíveis de cavings encontrados na fotografia da amostra (Figura 2).

Após a definição das classes de cada um dos grãos da imagem, o próximo passo foi o treinamento de uma versão do modelo de visão computacional YOLOv8 (Solawetz & Francesco, 2023), a qual permite a personalização das classes a serem preditas. Após esse treinamento do modelo, o próximo passo foi o teste com uma nova fotografia de outra amostra de calha contendo tanto cuttings (fragmentos de rocha

perfurados pela broca) como cavings (fragmentos de rocha desabados das paredes do poço), simulando uma amostra de calha real com os dois componentes (Figura 3).

Figura 2 – Cavings classificados de acordo com seu formato após a segmentação/delimitação usando SAM. Em amarelo: blocky; verde claro: angular; vermelho: tabular; roxo: splintery.



Fonte: elaboração própria

Figura 3 – Fotografia utilizada para predição dos tipos de cavings usando o modelo de visão computacional YOLOv8.



Fonte: elaboração própria

Resultados e Discussão

Com relação à caracterização dos litotipos dos cavings, esses são predominantemente folhelhos e rochas carbonáticas, possivelmente calcário e/ou margas. Os folhelhos são predominantemente cinza-escuros a pretos, semiduros a duros, com estrutura maciça a laminada. Ocasionalmente, ocorrem laminações de

composição de carbonato, que podem ou não conter pirita. As rochas carbonáticas, por outro lado, reagem na presença de ácido HCl 10% e diferem visualmente dos xistos principalmente em termos de coloração, variando de cinza-claro a cinza-acastanhado, além de textura fina e estrutura maciça. Quanto ao tamanho, os cavings variam de 1,0 cm a 4,0 cm (com uma média em torno de 2,0 cm), bem como formas variadas, de arredondadas a alongadas e achatadas, às vezes pontiagudas (Figura 1B).

Após o treinamento do YOLOv8 usando as classes definidas a partir da delimitação dos fragmentos de rocha usando o SAM (exemplo da Figura 2), observa-se que o modelo de visão computacional foi capaz de classificar corretamente os tipos de cavings esperados, mesmo esses estando imersos em um meio contendo cuttings (fragmentos de rocha de tamanho normal – provenientes da perfuração), como observado na Figura 3 a seguir. De maneira geral, o nível de certeza do modelo é em torno de 0,8, o que representa um considerável nível de confiança para aplicações em operações de campo, de maneira a auxiliar as equipes de geologia na identificação e classificação dos tipos de cavings presentes nas amostras de calha.


Figura 4 - Predição dos tipos de folhelho em amostra de calha através do modelo de visão computacional YOLOv8. Para cada fragmento, as labels contam com o nome da classe correspondente e o nível de certeza (variando de 0 a 1) que o modelo teve para classificar cada fragmento. Laranja: tabular; verde: blocky; azul: splintery; e vermelho: angular. Por motivos de simplificação, foi desabilitada a exibição das labels relacionadas aos fragmentos de menor tamanho (cuttings).



Fonte: elaboração própria.

Por fim, cabe salientar que além das classes de tipos de cavings (blocky, splintery, angular e tabular), durante a classificação dos fragmentos foi adicionada também a classe "cuttings" (exemplos desses fragmentos na Figura 1A) para representar o que não são cavings. Essa classe não foi plotada na Figura 3 por motivos de simplificação, mas o modelo de visão computacional também foi capaz de identificá-la com eficácia. No geral, esses cuttings também são fragmentos de folhelhos, margas e calcários, só que com menor tamanho (variando de 2 a 5 mm, com média em 3 mm).

Figura 5: Imagem com total segmentação de amostra do mesmo tamanho



Fonte: Elaboração Própria.

Conclusões

Em suma, este estudo destaca a importância crítica da classificação e caracterização dos cavings para garantir a segurança operacional e a eficiência na exploração de poços de petróleo, enfatizando a evolução das técnicas de análise para melhor compreensão e gestão dos riscos geológicos associados.

Agradecimentos

Ao apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Pela oportunidade de realizar este trabalho, ao Instituto Federal de Educação Ciência e Tecnologia (IFRN). Pela orientação e apoio durante este projeto, à Professora Doutora Rosiney Martins. Pelo fornecimento de dados e materiais que foram essenciais para o desenvolvimento da pesquisa, a todos da empresa Geowellex.

Referências Bibliográficas

RIBEIRO DE OLIVEIRA¹, M. et al. **DESCRIÇÃO DE AMOSTRAS DE CALHA DO POÇO 7-CLB-2-RN PERFURADO PELA EMPRESAPARTEX BRASIL NO CAMPO COLIBRI, BACIA POTIGUAR/RN.** [s.l.: s.n.]. Disponível em: <https://www.editorarealize.com.br/editora/anais/conepetro/2018/TRABALHO_EV104_MD1_SA98_ID185_06072018091034.pdf>. Acesso em: 28 jul. 2024.

HAN, Runqi. **Automated computer vision system for real-time drilling cuttings monitoring.** 2016. Tese de Doutorado.

HAN, Runqi et al. Real-time 3D computer vision shape analysis of cuttings and cavings. In: **SPE Annual Technical Conference and Exhibition?**. SPE, 2018. p. D022S048R001.

ANP - AGÊNCIA NACIONAL DO PETRÓLEO E GÁS NATURAL. Exploração e produção de óleo e gás - ANP. Disponível em: <<http://www.anp.gov.br/wwwanp/exploracao-e-producao-de-oleo-e-gas>>. Acesso em: 25 jul. 2024.

LOERMANS, T. et al. Advanced Mud Logging (AML) Aids Formation Evaluation and Drilling , and Yields Precise Hydrocarbon Fluid Composition. SPE Middle East Oil and Gas Show and Conference, p. 1–12, 2011.

LOERMANS, T. et al. SUCCESSFUL PILOT TESTING OF INTEGRATED ADVANCED MUD LOGGING UNIT. SPWLA 53rd Annual Logging Symposium, p. 1–6, 2012.

SOLAWETZ, Jacob; FRANCESCO. What is yolov8? the ultimate guide., 2023. Disponível em: <<https://blog.roboflow.com/whats-new-in-yolov8/>>.

Skea, C., Rezagholilou, R, Far, P. b., Gholami, r., Sarmadivleh, M.. An approach for wellbore failure analysis using rock cavings and image processing. Journal of Rock Mechanics and Geotechnical Engineering, 2018. Disponível em: <<https://espace.curtin.edu.au/bitstream/handle/20.500.11937/69509/267769.pdf;jsessionid=AF4502E0B68A693F6EC9BEF10FC8D57E?sequence=2>> . Acessado em: 09/08/2024.