



C A P Í T U L O 1

APLICAÇÃO DE MODELOS DE VISÃO COMPUTACIONAL PARA DETECÇÃO DE POCKMARKS EM IMAGENS DE SONAR DE VARREDURA LATERAL

Ester Cavalcante dos Santos

Emanuel Henrique Valença Silva

Arthur Antônio Machado

RESUMO: A detecção manual de pockmarks em imagens de sonar de varredura lateral (SSS) apresenta limitações operacionais, como alto tempo de processamento e baixa padronização analítica. Este trabalho teve como objetivo implementar e validar um modelo de detecção automática baseado na arquitetura YOLOv11, visando a identificação dessas feições na Baía de Todos os Santos (BTS), ambiente com registros de acúmulo de gás biogênico. O modelo foi treinado com 300 imagens anotadas (240 para treino e 60 para validação), e testado em seis níveis de confiança. A comparação com a contagem manual — 1.850 feições em 1h54min — indicou redução de até 226 vezes no tempo de execução, mantendo taxas de acerto superiores a 90% nos limiares mais altos. Os resultados evidenciam que a abordagem automatizada é eficaz para aplicações em ambientes marinhos, com ganho expressivo em desempenho e confiabilidade em relação ao método convencional.

PALAVRAS-CHAVE: *Pockmarks*, Gás Natural, Sonar de varredura lateral, YOLO, Visão computacional.

INTRODUÇÃO

O gás natural, composto predominantemente por metano (CH_4), pode ter origem biogênica, termogênica ou abiógênica (FARAMAWY *et al.*, 2016). Na Baía de Todos os Santos (BTS), os processos biogênicos são os principais responsáveis pela geração de metano, resultante da degradação anaeróbica de matéria orgânica depositada em sedimentos finos, como siltes e argilas, que apresentam baixa permeabilidade e elevada retenção de matéria orgânica (CAMPOS & DOMINGUEZ, 2011; GUIMARÃES, 2016). A liberação desse gás pode formar *pockmarks*, feições geomorfológicas caracterizadas por depressões circulares, cônicas ou elípticas no leito marinho, resultantes da exsudação de fluidos subsuperficiais (HOVLAND & JUDD, 1992; MAHIQUES *et al.*, 2017; RIYATNA, 2023).

A identificação e o mapeamento dessas estruturas são fundamentais para compreender a dinâmica da migração de gás e seus impactos ambientais e geológicos. Métodos acústicos, como o sonar de varredura lateral (SVL), permitem detectar essas feições com alta resolução e eficiência (KEY, 2000). No entanto, a correlação entre *pockmarks* e a presença de gás não é sempre direta, pois há registros de áreas com exsudação de gás sem a formação dessas feições, assim como *pockmarks* sem evidências de gás associado (ROGERS *et al.*, 2006). Estudos prévios indicam que na BTS, essas estruturas estão concentradas principalmente nas regiões noroeste, nordeste e na porção norte da Ilha de Itaparica, onde há indicativos de acúmulo de gás (CAMPOS & DOMINGUEZ, 2011).

A identificação manual de *pockmarks* em imagens de SVL é um processo que demanda tempo e está sujeito a variações interpretativas. A aplicação de inteligência artificial (IA) em geociências tem demonstrado potencial para otimizar essa etapa, permitindo o processamento automatizado de grandes volumes de dados com maior precisão e reproduzibilidade (DILHAN & SIYAMBALAPITIYA, 2022; LI *et al.*, 2020). Modelos baseados em redes neurais convolucionais, como o YOLO, têm se mostrado eficazes na detecção automática de padrões em imagens acústicas (WU *et al.*, 2021). Este estudo investiga a aplicação dessa abordagem na BTS, avaliando sua capacidade de identificação e mapeamento de *pockmarks* de forma sistemática e eficiente.

METODOLOGIA

Parâmetro adotado

O critério adotado para a identificação baseou-se na morfologia das feições (LONG *et al.*, 2017; HOVLAND & JUDD, 1992), considerando aspectos como contraste, formato circular ou elíptico e padrões de sombreamento característicos dessas estruturas. Para minimizar erros, a análise foi conduzida utilizando o protocolo no qual a imagem foi dividida em seções para contagem manual, sem transposição de imagem, assegurando que todas as áreas fossem examinadas com o mesmo nível de atenção (**Figura 1**). Devido à qualidade das imagens, especialmente em regiões de menor contraste ou onde as feições se sobrepõem a outras estruturas do fundo marinho, esse tipo de análise está sujeito a variabilidades no resultado da contagem. O treinamento do modelo de visão computacional levou 15 minutos com um notebook com um processador Intel Core i7 12th gen 1.7 GHz. O modelo então foi testado para seis níveis de confiança (100%, 90%, 80%, 70%, 60% e 50%).

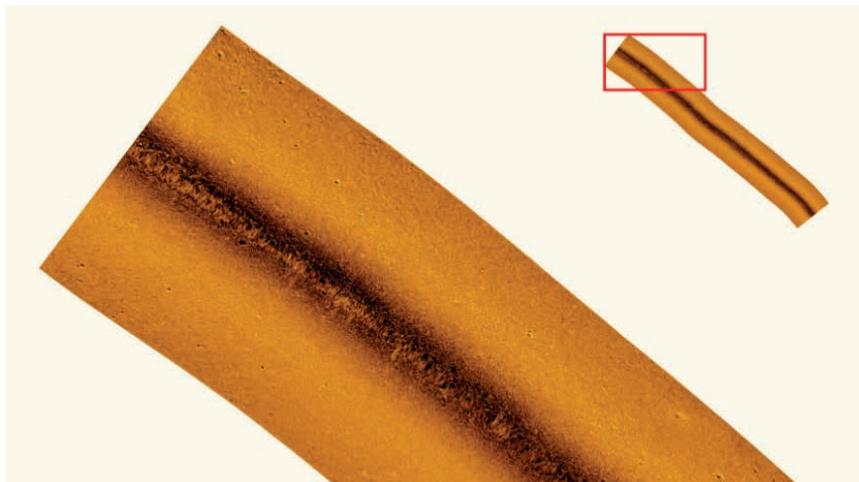
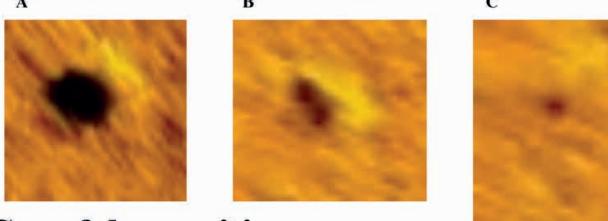


Figura 1 – Partição superior das imagens em seções definidas (2025).

Feições identificadas como positivas são visíveis ou com baixa deformação. Já os falsos positivos incluem feições que são pockmarks com deformações atípicas, parcialmente deformadas ou completamente ausentes (**Figura 2**).

Caso positivo:

Pockmarks claras ou em baixos níveis de deformação. Conforme exemplo abaixo.



Caso falso-positivo:

Pockmarks altamente deformadas, parcialmente deformadas e completamente ausente. Conforme exemplo abaixo.

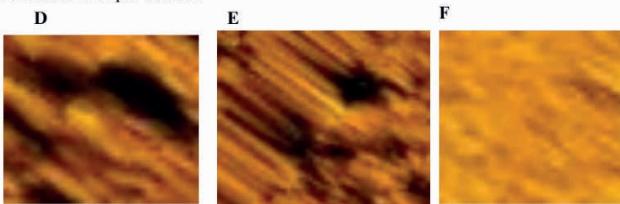


Figura 2 – Critério de avaliação das saídas do modelo e contagem manual (2025)

Criação do modelo de visão computacional

Para a geração do modelo de detecção de *pockmarks*, foi aplicado a arquitetura YOLO (You Only Look Once). YOLO é um método de detecção de objetos de passada única (*single pass*) que utiliza uma rede neural convolucional como extrator de características (*features*). Por intermédio da detecção de objetos com YOLO, é possível determinar o que está na imagem e onde um determinado objeto reside (BARBOSA, DALLA ROSA & RIEDER, 2024; SABINO *et al.*, 2022). O dataset utilizado para a construção do modelo de detecção foi utilizado dois subconjuntos: treinamento (80%, 240 imagens), validação (20%, 60 imagens).

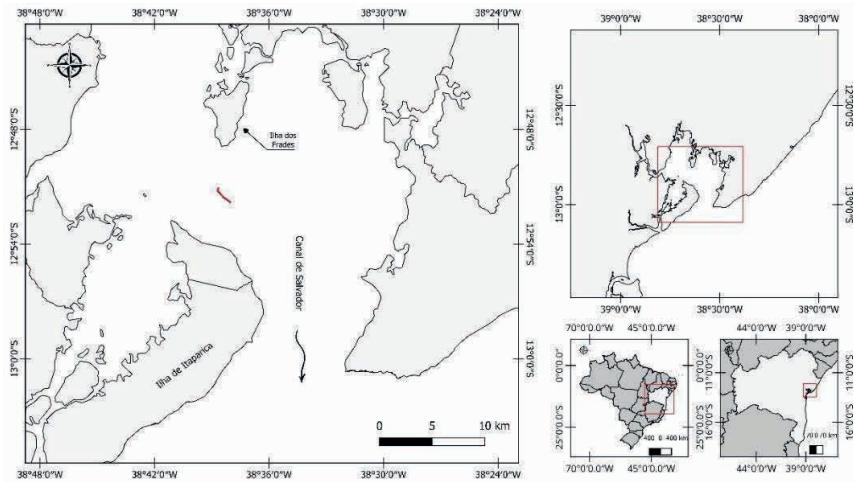
As imagens para a construção do modelo foram retiradas de dois cortes do GeoTIFF do mosaico da sonografia após seu processamento no software SonarWiz, com a aplicação das máscaras de detecção de objetos no LabelStudio (HumanSignal, 2019) e exportadas em formato compatível com o YOLO. Para a elaboração dos modelos foi utilizada a arquitetura YOLOv11l, cujo possui aproximadamente vinte e cinco camadas convolucionais e oitenta e sete camadas completamente conectadas. Para o treinamento da rede, foram utilizados como parâmetros: epochs = 100 (número de épocas para o treinamento), batch = 8 (tamanho do lote para cada iteração), Workers = 1 (número de *threads* de trabalho para carga de dados), device = 'cpu' (escolha do ambiente de processamento para "CPU", "GPU" compatível apenas com Nvidia (YOLO 11, 2024.).

Área de estudo

A Baía de Todos os Santos, a segunda maior do Brasil, com 1.233 km² (CIRANO e LESSA, 2007), é caracterizada por um fundo marinho composto por sedimentos siliciclásticos de origem fluvial e rochas da Bacia Sedimentar do Recôncavo (DOMINGUEZ e BITTENCOURT, 2009), além de sedimentos biogênicos provenientes da decomposição de organismos marinhos (LESSA *et al.*, 2000). A baía é delimitada pelas falhas de Maragogipe e Salvador (DOMINGUEZ e BITTENCOURT, 2009), apresentando uma geologia rica e complexa que influencia diretamente os processos sedimentares e biogênicos da região.

Coleta de Dados

As operações de aquisição de dados ocorreram entre os dias 27 e 29 de agosto de 2024, pela Marinha do Brasil, na porção central-norte da Baía de Todos os Santos (Mapa 1). O sonar de varredura lateral Klein 3000 foi utilizado, operando nas frequências de 100 e 500 kHz. A sondagem seguiu um percurso linear de 1,797 km, cobrindo uma área de aproximadamente 22,680 hectares.



Mapa 1 – Mapa da área de sondagem. Linha em vermelho representa linha de sondagem (2025).

O setor sondado é caracterizado por uma batimetria rasa, com profundidades variando entre 5,0 m e 29,0 m, e uma espessura sedimentar variando entre 1,05 m e 15,0 m. Durante a coleta, foram identificadas diferentes acumulações de gás, como Turbidez Acústica, zonas de sedimento fino sem gás (FSG) e zonas de embasamento acústico raso (CAMPOS e DOMINGUEZ, 2011). As acumulações de gás são mais expressivas no setor noroeste da baía, enquanto o setor central-norte apresenta ocorrências mais esparsas, distribuídas de maneira dispersa e a diferentes profundidades sob o sedimento (CAMPOS e DOMINGUEZ, 2011).

RESULTADOS E DISCUSSÃO

Identificação manual de *pockmarks*

A acumulação de gás na BTS é praticamente contínua em especial nos setores noroeste e nordeste, com descontinuações e espaçamentos na região do canal de Itaparica (CAMPOS e DOMINGUEZ, 2011). De acordo ainda com Campos e Dominguez (2011) a origem do gás acumulado é biogênica, especialmente na área do levantamento sonográfico, devido a ação de organismos metanogênico. As linhas 101800, 102800 e 113500 (Tabela 1), situadas na região mais a noroeste do setor centro-norte da BTS, apresentaram menores quantidades de *pockmarks*, o que pode estar relacionado à espessura do pacote sedimentar, que se mantém em torno de 5 metros ou menos (CAMPOS, 2010; CIRANO e LESSA, 2007). Nessa região, não

foram identificadas acumulações significativas de gás, e a batimetria relativamente rasa sugere condições menos favoráveis para o acúmulo de gás (CAMPOS, 2010). A contagem manual dos *pockmarks* identificou 1.850 *pockmarks* em uma duração total de 1 hora e 54 minutos.

No setor centro-norte inferior da BTS, observa-se uma maior quantidade de *pockmarks*, coincidindo com pacotes sedimentares mais espessos (5-15 metros) e uma batimetria mais profunda. Esses fatores sugerem que, em áreas com variações acentuadas de batimetria, ocorre a deposição preferencial de sedimentos finos e matéria orgânica, criando zonas favoráveis à acumulação de gás (CAMPOS, 2010). Essa característica é típica das zonas FSG, onde os sedimentos mistos apresentam baixa capacidade selante, permitindo o escape de gás para a coluna d'água (CAMPOS, 2010).

Ao comparar os dados obtidos para duas linhas neste setor, observa-se que na linha 100800 foram identificadas 221 *pockmarks* em um tempo de 7 minutos e 55,87 segundos. Já na linha 125500, foram contadas 212 *pockmarks* em 5 minutos e 35,07 segundos. Embora a diferença no número de feições seja relativamente pequena, o tempo de análise foi superior na linha 100800. Especificamente nesta linha, as *pockmarks* apresentavam menor contraste em relação ao fundo, exigindo um maior tempo para confirmação.

Linha	N. de <i>pockmarks</i>	Tempo
100800	221	7:55,87s
101800	69	2:30,20s
102800	72	1:53,26s
103800	328	7:07,80s
112500	212	5:35,07s
113500	96	2:07,40s
125500	161	3:03,30s
130500	127	2:21,78s
131500	165	2:48,39s
132500	230	4:27,28s
143700	169	4:48,88s

Tabela 1 – Tempo de detecção manual por linhas de sondagem (2025).

Aplicação do modelo de visão computacional

A aplicação do modelo com os dados de SVL revelou-se mais complexa do que inicialmente previsto. Embora o modelo tenha sido treinado utilizando mosaicos exportados do SonarWiz, a execução direta nestes mosaicos não foi viável devido à limitação de resolução máxima do YOLO, que é de 3840x2160 pixels. Para contornar essa restrição, os mosaicos foram segmentados de forma arbitrária, de modo a se

adequarem ao limite de resolução imposto pelo pacote. Isso pode ter afetado a taxa de detecção do programa. Outro fator que impactou a precisão do modelo foi a qualidade dos dados de SVL. A qualidade das imagens do sonar foi afetada por irregularidades na varredura, resultando em deformações que dificultaram a identificação das *pockmarks*. A falta de um trajeto linear na sondagem causou distorções, exigindo recortes para manter apenas as áreas de maior qualidade. Essas deformações impactaram tanto a contagem manual, aumentando a dificuldade e incerteza da identificação, quanto a detecção automatizada, especialmente em níveis de confiança mais baixos, onde há maior sensibilidade a variações na textura e contraste das imagens.

O modelo YOLOv11 demonstrou um desempenho significativamente mais eficiente, com tempos de processamento variando entre 47 e 120 segundos, dependendo do nível de confiança adotado, conforme ilustrado no Gráfico 1-a. As consideráveis reduções no tempo de processamento representam um ganho temporal expressivo, tornando o uso de inteligência artificial uma alternativa viável para análises que demandam rapidez sem comprometer substancialmente a qualidade da detecção. Em termos quantitativos, o modelo apresentou variações nos resultados conforme o nível de confiança estabelecido.

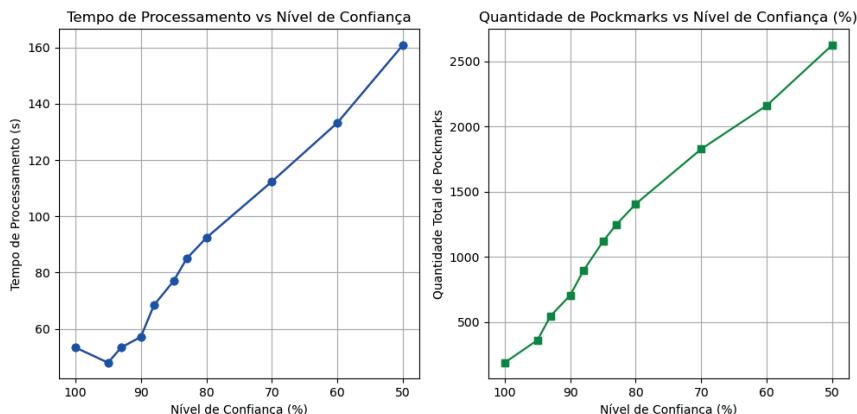


Gráfico 1 – a) relação entre o nível de confiança (%) e o tempo de processamento (s). b) quantidade total de *pockmarks*. O primeiro gráfico mostra como o tempo de processamento varia com o aumento do nível de confiança e número total de *pockmarks* detectados (2025)

A análise dos dados de taxa de acerto e níveis de confiança apresentados no texto revela uma relação inversa entre esses parâmetros. Em geral, conforme o nível de confiança aumenta, a taxa de acerto também tende a aumentar, até um certo

ponto. Para níveis de confiança mais elevados, como 100%, 95% e 93%, as taxas de acerto são de 100.00%, 99.17% e 98.54%, respectivamente. Esses altos níveis de confiança indicam uma detecção mais rigorosa e precisa dos *pockmarks*, com uma quantidade mínima de falsos positivos. Contudo, isso também pode resultar na perda da maior das detecções, afetando a abrangência do modelo.

À medida que os níveis de confiança diminuem, observa-se uma redução gradual na taxa de acerto. Por exemplo, com 90% e 88% de confiança, as taxas de acerto são de 98.30% e 95.30%. Nesse intervalo, ainda há um equilíbrio razoável entre precisão e sensibilidade, embora a ocorrência de falsos positivos comece a aumentar. Quando o nível de confiança cai para 85% e 83%, as taxas de acerto são de 93.56% e 89.57%. A partir deste ponto, há uma queda mais acentuada na precisão, evidenciando o aumento na detecção de *pockmarks*, incluindo possíveis falsos positivos. Por exemplo, com 80% de confiança, a taxa de acerto é de 89.22%, enquanto com 70% e 60%, as taxas caem para 88.32% e 76.85%, respectivamente. Finalmente, no nível de confiança de 50%, a taxa de acerto é de 75.81%, a mais baixa entre os pontos analisados. Isso demonstra uma alta sensibilidade do modelo que, embora detecte um grande número de *pockmarks*, inclui muitos falsos positivos, comprometendo a qualidade da detecção.

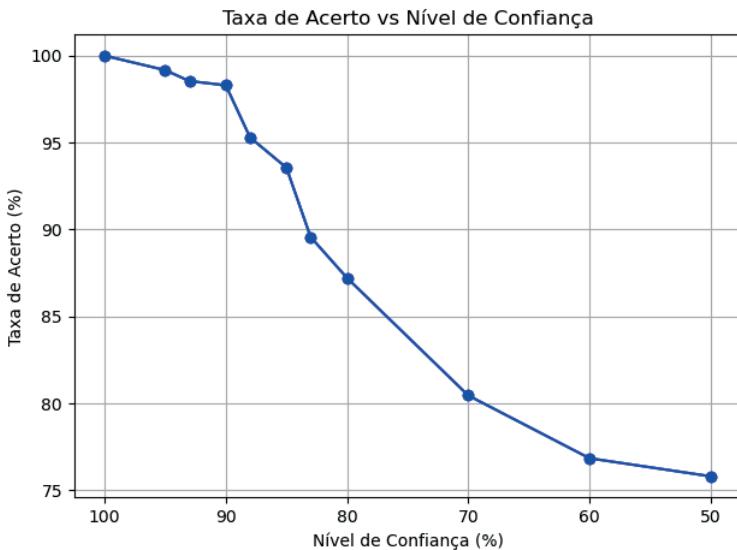


Gráfico 2 – Variação da taxa de acerto do modelo com a variação do nível de confiança (2025).

Ao repetir as análises das linhas 100800l e 125500l, nota-se que os diferentes níveis de confiança influenciam significativamente tanto a quantidade de *pockmarks* detectados quanto o tempo de processamento (Gráfico 3.a e 3.b). Para a linha 100800l, os níveis de confiança variam de 50% a 100%, resultando em detecções que vão de 214 *pockmarks* em 12.43 segundos a 17 *pockmarks* em 14.27 segundos. Já para a linha 125500l, as detecções variam de 161 *pockmarks* em 9.92 segundos a 5 *pockmarks* em 2.53 segundos. Esses dados ilustram claramente a relação inversa entre o nível de confiança e o tempo de processamento, além da variação na quantidade de *pockmarks* identificados.

Observa-se que a escolha do nível de confiança é crucial para equilibrar a sensibilidade e a precisão do modelo. Níveis mais altos de confiança reduzem o número de falsos positivos, mas também diminuem a quantidade de *pockmarks* detectados. Em contrapartida, níveis mais baixos de confiança aumentam a detecção, incluindo potenciais falsos positivos, como observado com 60% de confiança, onde a detecção subiu para 2161 *pockmarks*, ultrapassando a contagem manual em 16%.

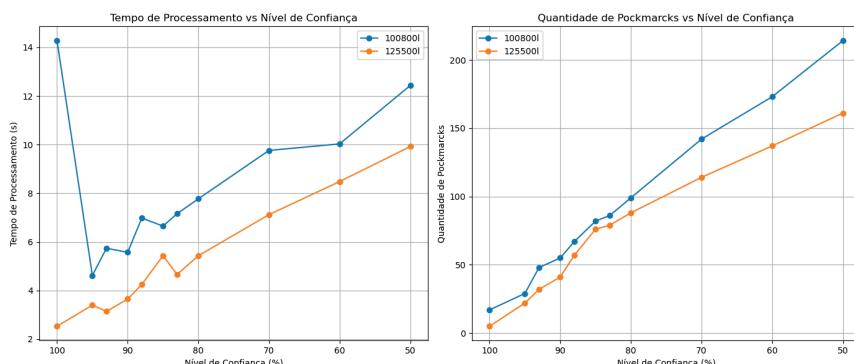


Gráfico 3 – a) relação entre o nível de confiança (%) e o tempo de processamento (s). b) quantidade total de *pockmarks*. o primeiro gráfico mostra como o tempo de processamento varia com o aumento do nível de confiança e número total de *pockmarks* detectados para as linhas 100800l e 125500l. (2025).

CONSIDERAÇÕES FINAIS

O uso do modelo YOLOv11 para a detecção de *pockmarks* na Baía de Todos os Santos demonstrou a viabilidade da aplicação de inteligência artificial no mapeamento geológico automatizado, promovendo uma redução significativa no tempo de análise e aumento da eficiência na identificação dessas feições. O modelo apresentou sensibilidade a diferentes limiares de confiança, permitindo calibrar o equilíbrio entre precisão e abrangência conforme os objetivos da análise.

A distribuição espacial dos *pockmarks* revelou correlações diretas com fatores sedimentares e batimétricos, indicando que a acumulação de gás biogênico está condicionada a variações geológicas locais. A maior densidade dessas feições em áreas com espessuras sedimentares mais elevadas reforça a influência da granulometria e da capacidade de retenção de matéria orgânica na gênese dos *pockmarks*.

A análise comparativa entre os métodos de detecção manual e automatizada evidenciou ganhos expressivos em tempo de processamento, com taxas de acerto superiores a 90% para níveis de confiança mais elevados. Contudo, verificou-se um aumento na ocorrência de falsos positivos em limiares mais baixos, o que destaca a necessidade de ajustes conforme a finalidade da investigação — seja ela de caráter exploratório, com maior sensibilidade, ou confirmatório, com foco em precisão.

Adicionalmente, distorções presentes nas imagens de sonar de varredura lateral, atribuídas à trajetória não linear da sondagem, impactaram a acurácia do modelo em áreas específicas. Esses resultados indicam que a padronização dos parâmetros de aquisição de dados é essencial para maximizar o desempenho de modelos baseados em aprendizado profundo. Ainda assim, a arquitetura YOLO demonstrou robustez frente à variabilidade morfológica dos *pockmarks*, especialmente em contextos sedimentares mais espessos e com evidência de acumulação de gás.

REFERÊNCIAS BIBLIOGRÁFICAS

BARBOSA, J. C. P.; DALLA ROSA, F.; RIEDER, R. Pothole Detection Web App: uma abordagem para detecção de buracos em pavimentos asfálticos utilizando YOLO. *Revista Brasileira de Computação Aplicada*, v. 16, n. 3, p. 25-36. 2024. Disponível em <https://doi.org/10.5335/rbca.v16i3.15851>. Acessado em 1 dez 2024 às 12h50.

CAMPOS, R. H. S. Ocorrências de gás nos sedimentos holocênicos da Baía de Todos os Santos: origem e distribuição. Universidade Federal da Bahia: Instituto de Geociências. 2010. 53 p. (Monografia de Graduação em Oceanografia). Disponível em <https://repositorio.ufba.br/handle/ri/27628>. Acessado em 10 dez 2024 às 16h00.

CAMPOS, R. H. S.; DOMINGUEZ, J. M. L. Shallow gas accumulations in the sediments of Todos os Santos bay (Bahia, Brazil): origin and distribution. 12th International Congress of the Brazilian Geophysical Society. European Association of Geoscientists & Engineers. In: *Anais*, pp. cp-264, 2011. Disponível em <https://library.seg.org/doi/10.1190/sbgf2011-383>. Acessado em 10 dez 2024 às 18h00.

CIRANO, M.; LESSA G. C. Oceanographic characteristics of Baía de Todos os Santos. Brasil. *Revista Brasileira de Geofísica*, v. 25, p. 363-387, 2007. Disponível em <https://doi.org/10.1590/S0102-261X2007000400002> Acessado em 08 dez 2024 às 09h30.

DE MAHIQUES, M.; SCHATTNER, U.; LAZAR, M.; SUMIDA, P. & SOUZA, L. An extensive pockmark field on the upper Atlantic margin of Southeast Brazil: spatial analysis and its relationship with salt diapirism. *Heliyon*, v. 3, n. 2, 2017. Disponível em 10.1016/j.heliyon.2017.e00257 Acessado em 12 dez 2024 às 10h20.

DILHAN, P.; SIYAMBALAPITIYA, R. Geological map feature extraction using object detection techniques - a comparative analysis. *i-manager's Journal on Image Processing*, v. 9, n. 2, p. 28-26. 2022. Disponível em <https://doi.org/10.26634/jip.9.2.18916> Acessado em 15 dez 2024 às 11h35.

DOMINGUEZ, J. M. L.; BITTENCOURT, A. C. S. P. Geologia da Baía de Todos os Santos. In: HATGE, V.; ANDRADE, J. B. (Org.). **Baía de Todos os Santos: aspectos oceanográficos**, cap. II, p. 25-66. 2009. Disponível em <http://www.repositorio.ufba.br/ri/handle/ufba/187>. Acessado em 17 dez 2024 às 09h50.

FARAMAWY, S.; ZAKI, T.; SAKR, A. Natural gas origin, composition, and processing: A review. **Journal of Natural Gas Science and Engineering**, v. 34, p. 34-54. 2016. Disponível em <https://doi.org/10.1016/j.jngse.2016.06.030>. Acessado em 02 dez 2024 às 17h50.

GUIMARÃES, L., 2016. Distribuição E Origem Da Matéria Orgânica Presente Nos Sedimentos Superficiais Depositados Da Baía De Todos Os Santos -Ba, Brasil. Monografia do Curso De Graduação Em Oceanografia. Universidade Federal Da Bahia. Instituto De Geociências. Disponível em <https://repositorio.ufba.br/handle/ri/27788>. Acessado em 11 dez 2024 às 18h50.

LONG, Y., GONG, Y., XIAO, Z., & LIU, Q. Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, p. 2486-2498, 2017. Disponível em <http://ieeexplore.ieee.org/document/7827088>. Acessado em 17 jan 2025 às 14h00

HOVLAND, M.; JUDD, A. The global production of methane from shallow submarine sources. **Continental Shelf Research**, v. 12, n. 10, p. 1231-1238. 1992. Disponível em [https://doi.org/10.1016/0278-4343\(92\)90082-U](https://doi.org/10.1016/0278-4343(92)90082-U). Acessado em 19 dez 2024 às 20h10.

LESSA, G.C.; BITTENCOURT, A.C.S.P.; BRICHTA, A.; DOMINGUEZ, J.M.L. A Reevaluation of the Late Quaternary Sedimentation in Todos os Santos Bay (BA), Brazil. **Anais da Academia Brasileira de Ciências**, v. 72, n. 4, p. 573-590. 2000 Disponível em <https://www.redalyc.org/articulo.oa?id=32772408>. Acessado em 14 dez 2024 às 07h00.

LI, Y.; ZHAO, Z.; LUO, Y.; QIU, Z. Real-Time Pattern-Recognition of GPR Images with YOLO v3 Implemented by Tensorflow. **Sensors (Basel, Switzerland)**, v. 20, n. 22, 2020 Disponível em <https://doi.org/10.3390/s20226476>. Acessado em 03 dez 2024 às 17h30.

RIYATNA, R., 2023. Identification Active Pockmarks Using The Combination Of Side Scan Sonar And Sub-bottom Profiler. *Journal of Marine-Earth Science and Technology*. V. 3, n. 3, p. 68-72. 2023. Disponível em <https://doi.org/10.12962/j27745449.v3i3.618> . Acessado em 06 dez 2024 às 08h50.

ROGERS, J.; KELLEY, J.; BELKNAP, D.; GONTZ, A.; BARNHARDT, W., 2006. Shallow-water pockmark formation in temperate estuaries: A consideration of origins in the western gulf of Maine with special focus on Belfast Bay. *Marine Geology*, v. 225, n. 1-4, p. 45-62. 2006. Disponível em <https://doi.org/10.1016/j.margeo.2005.07.011>. Acessado em 20 dez 2024 às 14h50.

SABINO, J. V.; DA SILVA, F. A.; DE ALMEIDA, L. L.; PEREIRA, D. R.; ARTERO, A. O. Utilizando Processamento De Imagens E Yolo Para A Construção De Um Sistema De Navegação De Um Drone Com Aplicação Em Uma Indústria. *Colloquium Exactarum. ISSN: 2178-8332*. v. 13, n. 4, p. 42-53. 2021 Disponível em <https://journal.unoeste.br/index.php/ce/article/view/4098> . Acessado em 07 dez 2024 às 09h00.

W. H. KEY. "Side scan sonar technology," OCEANS 2000 MTS/IEEE Conference and Exhibition. Conference Proceedings (Cat. No.00CH37158), Providence, RI, USA, v. 2, p. 1029-1033. 2000. Disponível em <https://ieeexplore.ieee.org/document/881735> . Acessado em 15 dez 2024 às 11h00.

WU, W.; LIU, H.; LI, L.; LONG, Y.; WANG, X.; WANG, Z., LI, J.; CHANG, Y. Application of local fully Convolutional Neural Network combined with YOLO v5 algorithm in small target detection of remote sensing image. *PLoS ONE*, v. 18, n. 9. 2021. Disponível em <https://doi.org/10.1371/journal.pone.0259283> . Acessado em 12 dez 2024 às 06h50.

AGRADECIMENTOS

A Marinha do Brasil por ceder os dados utilizados.