

Nº 179998

Detecção de feições geológicas combinando atributos sísmicos e o modelo segment anything2

**Gustavo Torres Custódio
Hugo Ferreira Saar
Thiago Yuji Aoyagi
Elisa Morandé Sales**

*Pôster apresentado no
CONGRESSO DE MODELAGEM,
SIMULAÇÃO COMPUTACIONAL
E IA DO IPT, 1, 2025, São Paulo.
4 p.*

A série "Comunicação Técnica" compreende trabalhos elaborados por técnicos do IPT, apresentados em eventos, publicados em revistas especializadas ou quando seu conteúdo apresentar relevância pública.
PROIBIDO A REPRODUÇÃO, APENAS PARA CONSULTA.



DETECÇÃO DE FEIÇÕES GEOLÓGICAS COMBINANDO ATRIBUTOS SÍSMICOS E O MODELO SEGMENT ANYTHING 2

Gustavo CUSTODIO¹, Hugo SAAR¹, Thiago AOYAGI¹, Elisa SALES¹

¹Instituto de Pesquisas Tecnológicas do Estado de São Paulo

Introdução

A interpretação manual de dados sísmicos é um processo demorado e custoso. O uso de atributos sísmicos facilita essa tarefa, mas ainda não captura todas as feições. Nesse contexto, cresce o interesse pelo uso de técnicas de *Machine Learning* para automatizar a interpretação. Neste trabalho, exploramos o *Segment Anything Model 2* (SAM 2), desenvolvido pela Meta AI [1], originalmente voltado à segmentação de qualquer objeto em imagens RGB. Dados sísmicos só precisam de um único canal, então investigamos a utilização de diferentes atributos sísmicos distribuídos nos três canais da imagem, adicionando informação e potencializando a segmentação.

Metodologia

Este trabalho realizou o *fine-tuning* do modelo SAM 2 para segmentação de geocorpos e camadas sísmicas, utilizando diferentes combinações de atributos sísmicos. O processo foi dividido em três etapas: preparação dos dados, extração e combinação de atributos, e treinamento do modelo.

Preparação dos dados: foram utilizadas três bases públicas: F3 offshore da Holanda, Parihaka da Nova Zelândia e Penobscot da Nova Escócia. Das seções sísmicas (*inlines* e *crosslines*) foram extraídas 220 imagens.

Extração de atributos sísmicos: Os atributos sísmicos foram calculados utilizando a biblioteca de Python d2geo [2]. além da amplitude, cinco atributos foram calculados (envelope, *root mean square* - RMS, filtro Gaussiano, cosseno da fase instantânea e variação relativa da amplitude). Para gerar imagens RGB, diferentes combinações de três atributos foram testadas, buscando enriquecer a entrada do modelo e evitar redundância de canais. Exemplos são mostrados na Figura 1.




Figura 1: Exemplo de um *inline* do volume F3 quando diferentes atributos sísmicos são combinados nos canais de cores.

Treinamento do modelo: foi realizado o *fine-tuning* do SAM 2 (*large*, 224,4M parâmetros) por 200 épocas. A função custo adaptada de Kirillov et al. [3] combinou *focal loss* e *dice loss*, acrescida da diferença entre IoU (*intersection over union*) previsto e esperado para melhor supervisão. O modelo recebeu pares de imagem e *prompt*, sendo cada *prompt* escolhido aleatoriamente dentro da máscara de segmentação.

Resultados

O desempenho do SAM 2 *large* na tarefa de segmentação foi comparado para diferentes combinações de atributos. A Tabela 1 mostra os valores das métricas de avaliação para cada combinação de três atributos. As métricas foram calculadas utilizando uma média de 50 épocas no conjunto de teste. Em cada época, foi selecionado um conjunto diferente de amostras, acompanhado de um *prompt* aleatório.

Combinação	Atributos (RGB)	Precisão	Recall	F1	IoU
1	Amplitude 3 canais	0,9216	0,9094	0,9096	0,8549
2	Amplitude + CFI + RMS	0,8878	0,8715	0,8705	0,7972
3	Envelope + CFI + Amplitude	0,9155	0,8964	0,8993	0,8398
4	Var. Amp. + CFI + RMS	0,9135	0,9028	0,9016	0,8436
5	Amplitude + Gauss + Var. Amp.	0,9302	0,9167	0,9184	0,8694

Tabela 1: Desempenho do SAM2 *Large* para diferentes conjuntos de atributos

A maioria das combinações de atributos apresentaram resultados inferiores ao uso da amplitude pura, exceto pela combinação 5. Os melhores desempenhos do SAM 2 foram obtidos com as combinações 4 e 5, cujas imagens geradas se assemelham visualmente às imagens de amplitude. A Figura 2 mostra resultados visuais para diferentes atributos.




Figura 2: Resultados visuais do SAM 2 em diferentes conjuntos de atributos

Conclusões

Verificamos que o desempenho do SAM 2 ajustado (*fine-tuned*) varia conforme os atributos escolhidos. Embora as imagens de amplitude tenham um bom desempenho, certas combinações de atributos podem ser igualmente ou mais eficazes, principalmente em imagens sísmicas com cores mais homogêneas. Acredita-se que a alternância de cores em algumas combinações possa causar segmentação incompleta. Como trabalho futuro, sugere-se testar novas combinações de atributos.

Referências

- [1] RAVI, N.; GABEUR, V.; HU, Y.-T.; HU, R.; RYALI, C.; MA, T.; KHEDR, H.; RÄDLE, R.; ROLLAND, C.; GUSTAFSON, L.; et al. Sam 2: Segment anything in images and videos. arXiv preprint, arXiv:2408.00714, 2024. Disponível em: <https://arxiv.org/abs/2408.00714>. Acesso em: 5 set. 2025.
- [2] FITZ-GERALD, B. D2geo: A framework for computing seismic attributes with Python. 2018. Disponível em: <https://github.com/dfitzgerald3>. Acesso em: 5 set. 2025.
- [3] KIRILLOV, A.; MINTUN, E.; RAVI, N.; MAO, H.; ROLLAND, C.; GUSTAFSON, L.; XIAO, T.; WHITEHEAD, S.; BERG, A. C.; LO, W.-Y.; et al. Segment anything. In: Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023. p. 4015–4026.