

**Nº 179430**

**Identificação de feições geológicas em dados sísmicos por meio de inteligência artificial: estado da prática, parte II**

**Carlos Tadeu de Carvalho Gamba**

**Hugo Ferreira Saar**

**Leonides Guireli Neto**

**Otávio Coaracy Brasil Gandolfo**

**Denis Bruno Virissimo**

**Aline Fernandes Heleno**

**Elisa Morande Sales**

**Celso Luciano Alves da Silva**

**Cristina Maria Ferreira**

**Felipe Silva Silles**

**Gustavo Torres Custódio**

**Ney Ferreira de Souza Guerra**

**Thiago Yuji Aoyaji**

*Palestra apresentada no  
Workshop Petrobras, 1., 2024,  
Rio de Janeiro. 110 slides*

*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 REPRODUÇÃO**



# I WORKSHOP PETROBRAS - IPT

EDISEN – RIO DE JANEIRO – 05.11 A 07.11.2024

*Unidade de Cidades, Infraestrutura e Meio Ambiente*

Carlos Tadeu de Carvalho Gamba, Hugo Ferreira Saar, Leonides Guireli Neto, Otávio Coaracy Brasil Gandolfo

*Unidade de Tecnologias Digitais*

Denis Bruno Virissimo, Aline Fernandes Heleno, Celso Luciano Alves da Silva, Cristina Maria Ferreira da Silva, ), Elisa Morande Sales, Felipe Silva Silles, **Gustavo Torres Custodio** (palestrante), Ney Ferreira de Souza Guerra, **Thiago Yuji Aoyagi** (palestrante)



---

# PETROBRAS

## IDENTIFICAÇÃO DE FEIÇÕES GEOLÓGICAS EM DADOS SÍSMICOS POR MEIO DE INTELIGÊNCIA ARTIFICIAL

### ESTADO DA PRÁTICA – PARTE II

06.11.2024

# WORKSHOP 2024: ESTADO DA PRÁTICA

## Introdução

- Reprodução de artigos da literatura relevantes para o objetivo do projeto
- Visualização e processamento de dados sísmicos
- Implementação preliminar de técnicas de machine learning e deep learning usados em segmentação de feições sísmicas
- Experimentações iniciais além dos artigos
- Prioridade para artigos com código fonte disponível

# ESTADO DA PRÁTICA: AGENDA

1. **Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado**
2. **Detecção de falhas com deep learning (DL)**
3. **Detecção de canais com DL**
4. **Segmentação de feições com foundation models**
5. **Estimação de RGT com DL**

# ESTADO DA PRÁTICA: AGENDA

- 1. Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado**
2. Detecção de falhas com deep learning (DL)
3. Detecção de canais com DL
4. Segmentação de feições com foundation models
5. Estimação de RGT com DL

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Referências (2017 e 2019)

### **Seismic fault detection based on multi-attribute support vector machine analysis**

*Haibin Di<sup>\*</sup>, Muhammad A. Shafiq, and Ghassan AlRegib*

*Center for Energy and Geo Processing (CeGP), Georgia Institute of Technology*

### **Improving seismic fault detection by super-attribute-based classification**

Haibin Di<sup>1</sup>, Mohammod Amir Shafiq<sup>2</sup>, Zhen Wang<sup>2</sup>, and Ghassan AlRegib<sup>2</sup>


#### **Abstract**

Fault interpretation is one of the routine processes used for subsurface structure mapping and reservoir characterization from 3D seismic data. Various techniques have been developed for computer-aided fault imaging in the past few decades; for example, the conventional methods of edge detection, curvature analysis, red-green-blue rendering, and the popular machine-learning methods such as the support vector machine (SVM), the

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Seismic fault detection based on multi-attribute support vector machine analysis (2017)

- Pontos azuis são falhas e pontos roxos representam regiões sem falhas.
- No total, **171 pontos com falhas** e **722 sem falhas** são escolhidos.
- Cada ponto utiliza um conjunto de atributos como features.






# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Seismic fault detection based on multi-attribute support vector machine analysis (2017)

- Foram selecionados **14 atributos** diferentes.
- Os atributos são divididos em grupos:
  - Atributos geométricos;
  - Atributos de detecção de borda;
  - Atributos de textura.
- Também foi realizada uma análise de importância para cada atributo.

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS



| Group   | Attribute              | Weight (%)   |
|---|------------------------|--------------|
| Geometric attribute<br>(Weights=25.56)        | Dip                    | 0.89         |
|   | Curvature              | 2.46         |
|   | Flexure                | 2.27         |
|   | <b>Geometric fault</b> | <b>19.94</b> |
| Edge-detection attribute<br>(Weights = 56.07) | Coherence              | 0.43         |
|   | Sobel edge             | 0.56         |
|   | Semblance              | 0.07         |
|   | Canny edge             | 0.38         |
|   | Similarity             | 0.04         |
|   | <b>Variance</b>        | <b>54.59</b> |
|   | <b>GLCM contrast</b>   | <b>13.07</b> |
| Texture attribute<br>(Weights = 18.37)        | GLCM homogeneity       | 1.80         |
|   | Gradient of texture    | 0.60         |
|   | Saliency               | 2.90         |

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas baseada em atributos sísmicos

- Experimentos realizados no cubo F3.
- Atributos selecionados:
  - Amplitude;
  - Coerência;
  - Similaridade;
  - Variância.
- 2 tipos de experimentos:
  - Atributos puros;
  - Aplicação de um **filtro orientado a estrutura (Structure-oriented filtering)**

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas baseada em atributos sísmicos

- O volume foi separado em treinamento e teste.
  - As duas regiões foram separadas no crossline 600.
- Os pontos com falhas na região de treinamento foram escolhidos para treinar o modelo junto com pontos onde falhas não estão presentes.
- Foram selecionados **49818 pontos de treinamento e 34551 pontos de teste.**

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

- Geramos uma base de dados em que cada **linha** representa um **ponto** e cada **coluna** representa um **atributo** diferente.
- Exemplo:

|       | Cubo original | Coerência | Fase Instantânea | Frequência Média | RMS | Semblance | Textura | Falha? |
|-------|---------------|-----------|------------------|------------------|-----|-----------|---------|--------|
| 1     | 0.2           | 0.1       | 0.7              | 0.0              | 0.4 | 0.6       | 0.6     | 0      |
| 2     | 0.8           | 0.2       | 0.3              | 0.9              | 0.1 | 0.2       | 0       | 0      |
| 3     | 0.9           | 0.5       | 0.8              | 0.1              | 0.2 | 0.3       | 0.3     | 0      |
| ...   | ...           | ...       | ...              | ...              | ... | ...       | ...     | ...    |
| 29999 | 0.1           | 0.9       | 0.9              | 0.8              | 0.2 | 0.5       | 0.7     | 1      |
| 30000 | 0.7           | 0.3       | 0.5              | 0.1              | 0.9 | 0.4       | 0.1     | 1      |

- Cada valor corresponde à cor do pixel em tons de cinza.
- Os dados são normalizados entre -1 e 1.

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados

- Separamos **90% dos pontos para treinamento e 10% para validação.**
- Realizamos uma **validação cruzada com 10 folds.**
- 5 modelos de Machine Learning foram comparados:
  - Random Forest;
  - Multi-Layer Perceptron;
  - Gradient Boosting;
  - XGBoost;
  - SVM.
- O modelo que conseguiu melhor resultado na validação cruzada foi o **Random Forest.**

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados



- Comparamos a classificação utilizando atributos com e sem a aplicação do filtro .

| Modelo     | Acurácia | Recall | Precisão | F1   |
|------------|----------|--------|----------|------|
| Sem filtro | 0.79     | 0.80   | 0.79     | 0.80 |
| Filtrado   | 0.79     | 0.79   | 0.79     | 0.79 |

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados

- Teste para o volume sem filtros:







# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados

- Teste para o volume filtrado:




# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados

- Também foi realizado um teste considerando um conjunto mais amplo de atributos (sem aplicação de filtro):
  - Amplitude;
  - Coerência
  - Fase instantânea;
  - Frequência;
  - RMS;
  - Semblance;
  - Similaridade;
  - Textura;
  - Variância

# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

Detecção de falhas utilizando métodos supervisionados



# ESTADO DA PRÁTICA: CLASSIFICAÇÃO DE FALHAS USANDO ATRIBUTOS SÍSMICOS

## Detecção de falhas utilizando métodos supervisionados

- Apesar de conseguir melhores resultados na validação cruzada, o cubo sem filtros apresentou **maior quantidade de ruído**.
- O filtro aplicado eliminou uma quantidade considerável de ruído.
- Um maior conjunto de atributos mesmo sem o filtro aplicado resultou em menos ruídos que os dois testes anteriores.

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Referência (2019)

### A comparison of classification techniques for seismic facies recognition

Tao Zhao<sup>1</sup>, Vikram Jayaram<sup>2</sup>, Atish Roy<sup>3</sup>, and Kurt J. Marfurt<sup>1</sup>

#### Abstract

During the past decade, the size of 3D seismic data volumes and the number of seismic attributes have increased to the extent that it is difficult, if not impossible, for interpreters to examine every seismic line and time slice. To address this problem, several seismic facies classification algorithms including *k*-means, self-organizing maps, generative topographic mapping, support vector machines, Gaussian mixture models, and artificial neural networks have been successfully used to extract features of geologic interest from multiple volumes. Although well documented in the literature, the terminology and complexity of these algorithms may bewilder the average seismic interpreter, and few papers have applied these competing methods to the same data volume. We have reviewed six commonly used algorithms and applied them to a single 3D seismic data volume acquired over the Canterbury Basin, offshore New Zealand, where one of the main objectives was to differentiate the architectural elements of a turbidite system. Not surprisingly, the most important parameter in this analysis was the choice of the correct input attributes, which in turn depended on careful pattern recognition by the interpreter. We found that supervised learning methods provided accurate estimates of the desired seismic facies, whereas unsupervised learning methods also highlighted features that might otherwise be overlooked.

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Agrupamento não supervisionado

- Foram executados algoritmos de agrupamento em inlines e crosslines específicos do cubo F3.
- Inlines: 280, 350 e 680.
- Crosslines: 910.
- 3 algoritmos não supervisionados diferentes foram utilizados:
  - K-Means;
  - SOM (Self-Organizing Maps);
  - GMM (Gaussian Mixture Models).

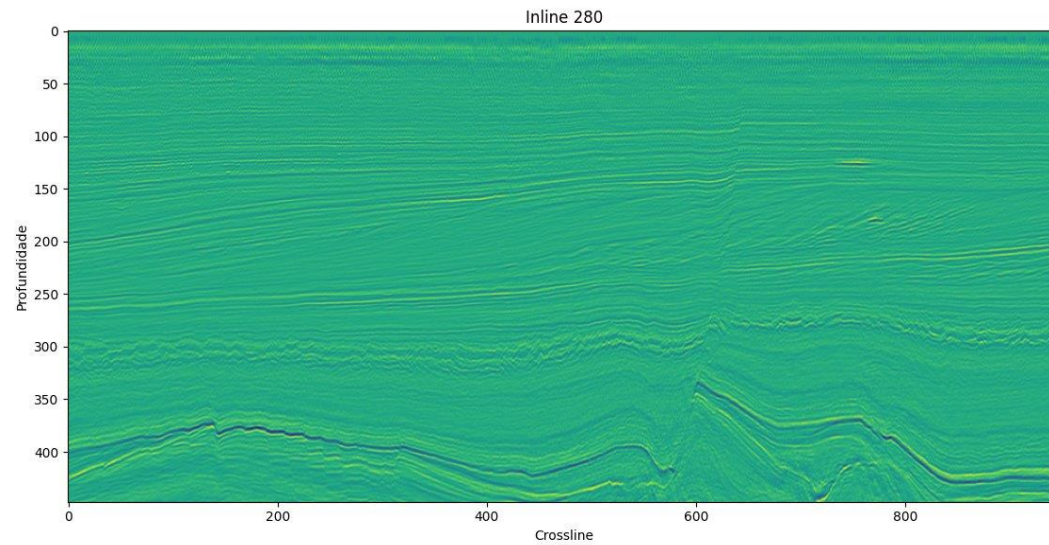
# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Agrupamento não supervisionado

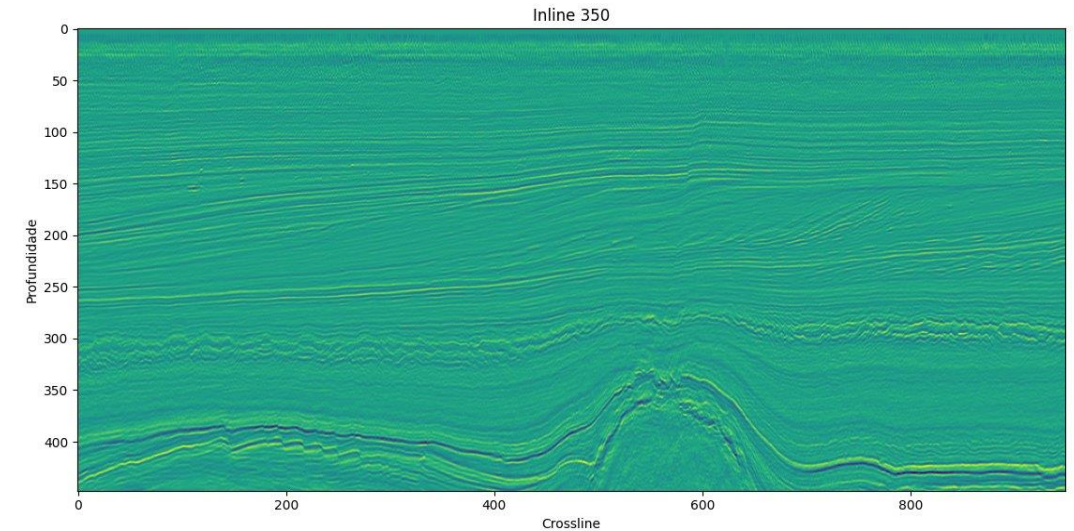
- Utilizamos os mesmos atributos utilizados na classificação supervisionada:
  - Amplitude;
  - Coerência
  - Fase instantânea;
  - Frequência;
  - RMS;
  - Semblance;
  - Similaridade;
  - Textura;
  - Variância

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## INLINE 280





## INLINE 350





# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

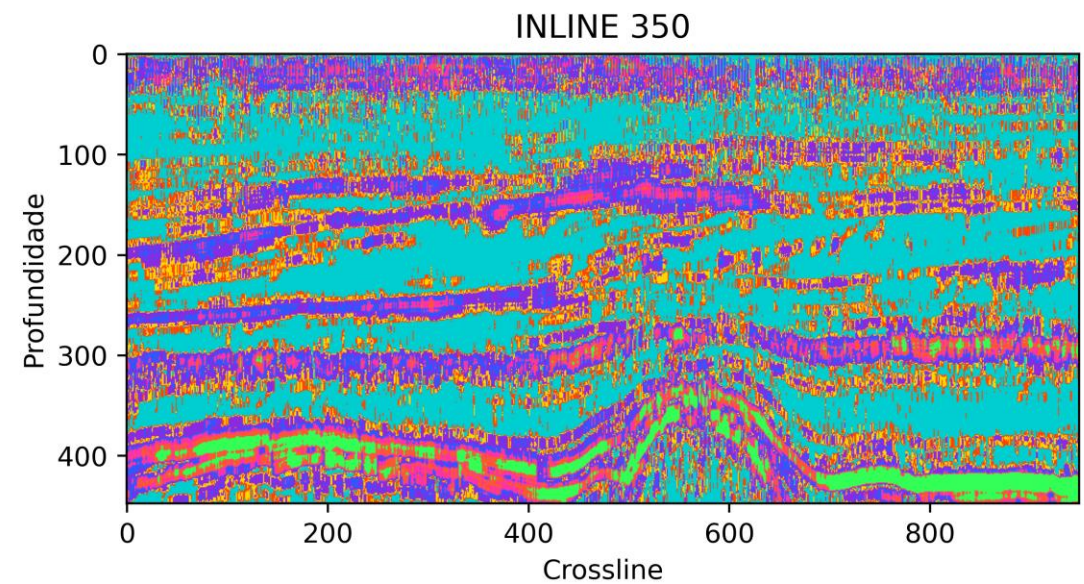
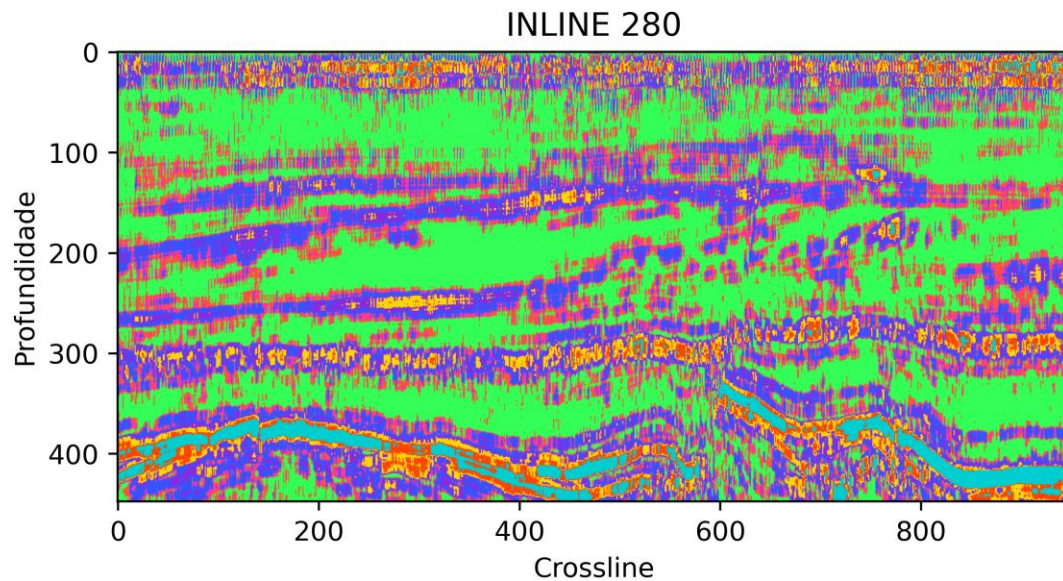
## Resultado para o k-Means



12 grupos

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Resultado para a rede SOM

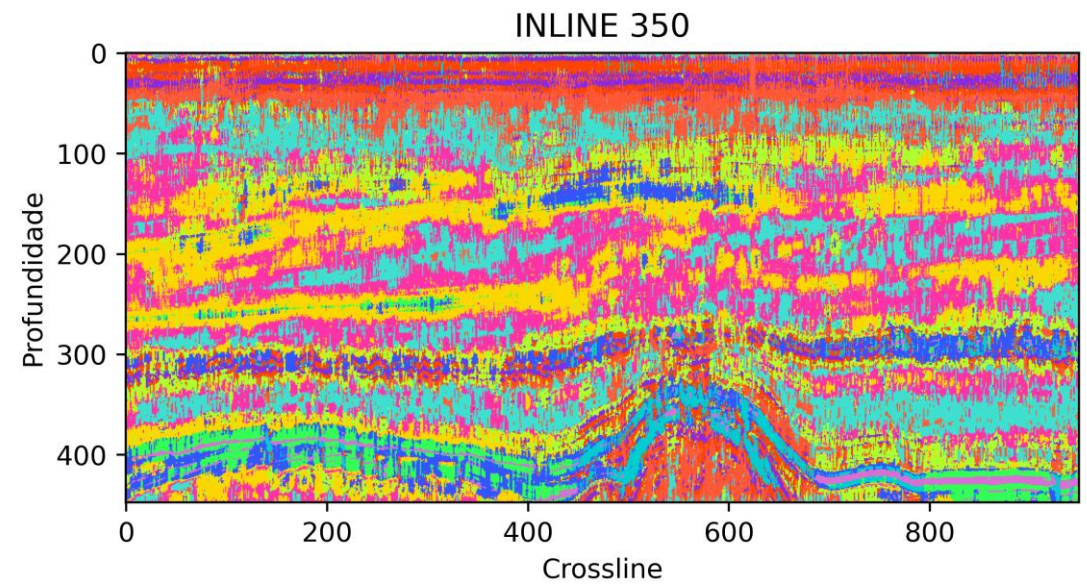



$M = 4$  (dimensão vertical da rede SOM).

$N = 2$  (dimensão horizontal da rede SOM).

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Resultado para o algoritmo GMM



12 grupos

# ESTADO DA PRÁTICA: AGRUPAMENTO NÃO-SUPERVISIONADO

## Agrupamento não supervisionado

- O **GMM com 12 grupos** foi o algoritmo que melhor refletiu as variações de fâcies nas camadas do F3.
  - Com destaque para os inlines 280 e 350.
- A rede SOM e o GMM apresentaram resultados melhores que o k-Means.
- Em geral, os algoritmos não supervisionados apresentam desempenho inferior a métodos supervisionados para a segmentação de feições.
- No entanto, o conhecimento adquirido em métodos não supervisionados pode **complementar métodos supervisionados** (Zhao et al., 2019).

# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Seismic Stratigraphic Interpretation Based on Unsupervised Validation and Spectral Clustering Sampling

- Jianyu Luo, Xiaofeng Gu, Wenkai Lu e Yinshuo Li (2024)
- Experimentos realizados no cubo F3 nos inlines 100 a 700.
- Entre o conteúdo proposto, é proposta uma **forma de avaliação não-supervisionada** (não depende dos dados rotulados para fazer uma avaliação de qualidade)

# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Seismic Stratigraphic Interpretation Based on Unsupervised Validation and Spectral Clustering Sampling

- O autor propõe uma métrica de avaliação chamada Sum of Differences (SD) para avaliação de detecção de falhas.
  - A métrica é a diferença entre a previsão dos rótulos de inlines vizinhos.
  - A ideia é que **inlines próximos tenham feições similares** (continuidade).

# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Seismic Stratigraphic Interpretation Based on Unsupervised Validation and Spectral Clustering Sampling

$$\delta(x_{ij}, y_{ij}) = \begin{cases} 0, & x_{ij} = y_{ij} \\ 1, & x_{ij} \neq y_{ij} \end{cases}$$


$$D(X, Y) = \sum_{i=1}^n \sum_{j=1}^m \delta(x_{ij}, y_{ij})$$

$$SD = \sum_{i=2}^{N-1} D(Y_i, Y_{i-1}) + D(Y_i, Y_{i+1})$$


# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Testes da métrica em cubos de atributos


Sem filtro:  
 $2.32 \times 10^8$



Filtrado:  
 $3.04 \times 10^8$



Todos os atributos:  
 $3.97 \times 10^7$





# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Conclusões

- Um número maior de atributos resultou em melhor discriminação entre falhas e não falhas, além de produzir menos ruído.
- Nos experimentos utilizando algoritmos de agrupamento, os melhores resultados em termos de refletir variações de fácies foram obtidos pelo GMM.
- A métrica SD tem correlação com métricas supervisionadas e foi condizente com resultados esperados quando aplicada para avaliar os cubos gerados na predição de falhas.

# ESTADO DA PRÁTICA: MÉTODO DE AVALIAÇÃO NÃO SUPERVISIONADO

## Perspectivas futuras

- Comparar o SD com formas de avaliação supervisionada.
- Incorporar o SD como uma função de loss.
- Criar um novo atributo indicando qual é o grupo de cada ponto.

# ESTADO DA PRÁTICA: AGENDA

1. Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado
- 2. Detecção de falhas com deep learning (DL)**
3. Detecção de canais com DL
4. Segmentação de feições com foundation models
5. Estimação de RGT com DL

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

Segmentação de falhas em dados 3D com CNN (3 artigos)

- **Xinming Wu 2019: FaultSeg3D**
- **Yimin Dou 2022: MD Loss**
- **Shaohuang Zu 2024: ResACEUnet**


# ESTADO DA PRÁTICA: DADOS SÍSMICOS SINTÉTICOS

- Facilidade em prover grande quantidade de **dados rotulados** para treinamento de modelos (principalmente em deep learning)
- Problemas:
  - Pouca complexidade e diversidade em comparação com dados reais de campo


# ESTADO DA PRÁTICA: DADOS SÍSMICOS SINTÉTICOS

## Exemplos

- **Wu, X., and Hale, D., 2016**, 3D seismic image processing for faults: Geophysics, 81, no. 2, IM1–IM11, doi: 10.1190/geo2015-0380.1.



Sísmica



Falhas



# ESTADO DA PRÁTICA: DADOS SÍSMICOS SINTÉTICOS

## Exemplos

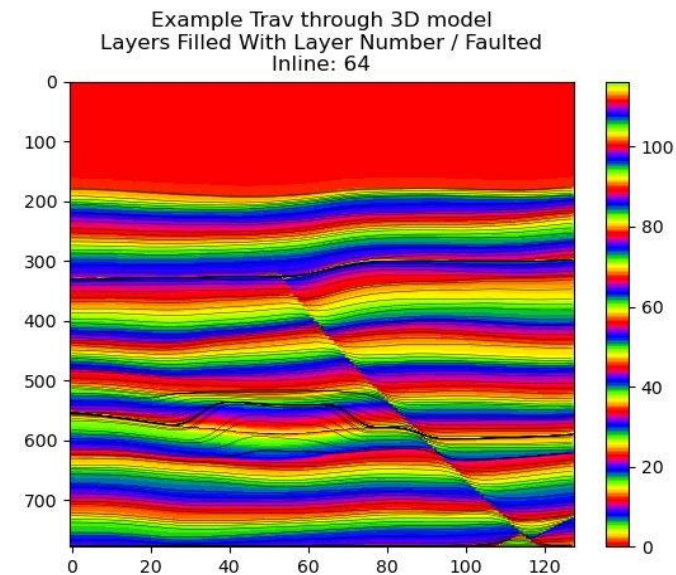
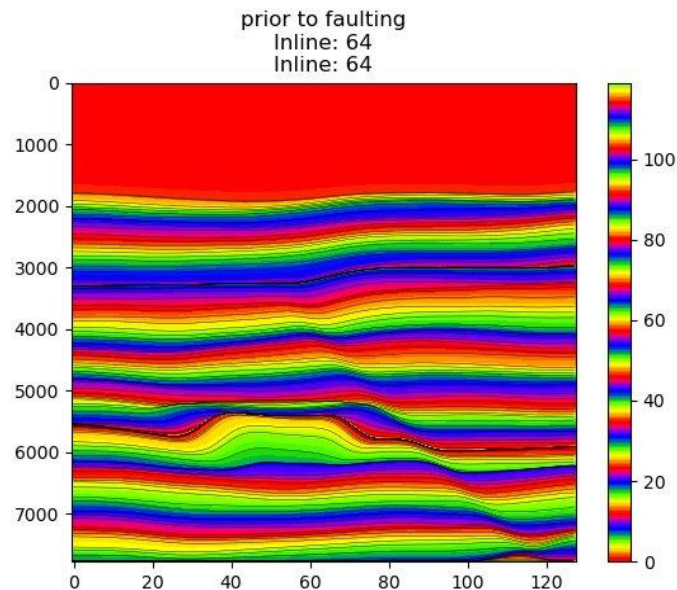
- **Merrifield, T. P., Griffith, D. P., Zamanian, S. A., Gesbert, S., et al., 2022,** Synthetic seismic data for training deep learning networks: Interpretation, 10, no. 3, SE31-SE39, doi: 10.1190/INT-2021-0193.1.
- Código aberto: <https://github.com/sede-open/synthoiseis>

SYNTHOISEIS

# ESTADO DA PRÁTICA: DADOS SÍSMICOS SINTÉTICOS

## Exemplos

- Synthosesis:
  - Simulação de coeficientes de reflexão e propriedades de rochas
  - Domos de sal, falha, canais, fechamentos





# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING


## FaultSeg3D (Wu, et al., 2019)

- **Wu, X., Liang, L., Shi, Y., & Fomel, S., 2019**, FaultSeg3D: using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation: *Geophysics*, 84, no. 3, IM35-IM45, doi: 10.1190/geo2018-0646.1.
- Método de segmentação: U-Net adaptada
- Dados sintéticos para treinamento (Wu, X., and Hale, D., 2016)
  - 220 volumes 128 x 128 x 128 (20 para teste)
- Treinamento com 25 épocas, atingindo acurácia de 95%

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## FaultSeg3D (Wu, et al., 2019)

- Rede neural: U-Net reduzida e modificada para 3D

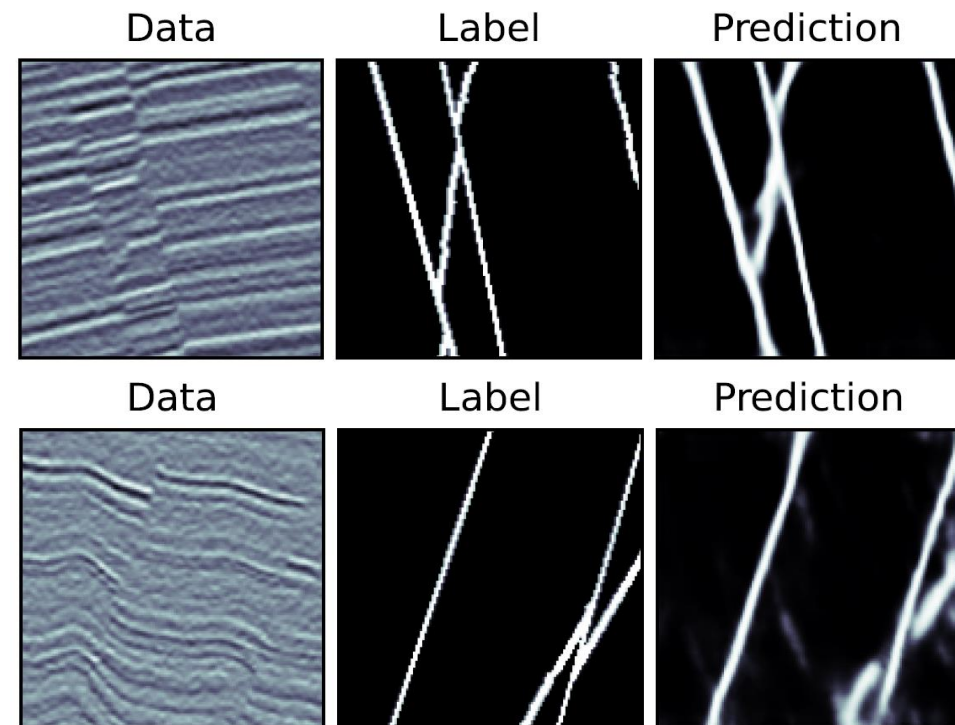


# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## FaultSeg3D (Wu, et al., 2019)

- Adaptações para reprodução:
  - entrada menor (96 x 96 x 96)
  - menos canais na última camada do encoder
- Treinamento com 35 épocas, acurácia de 93%

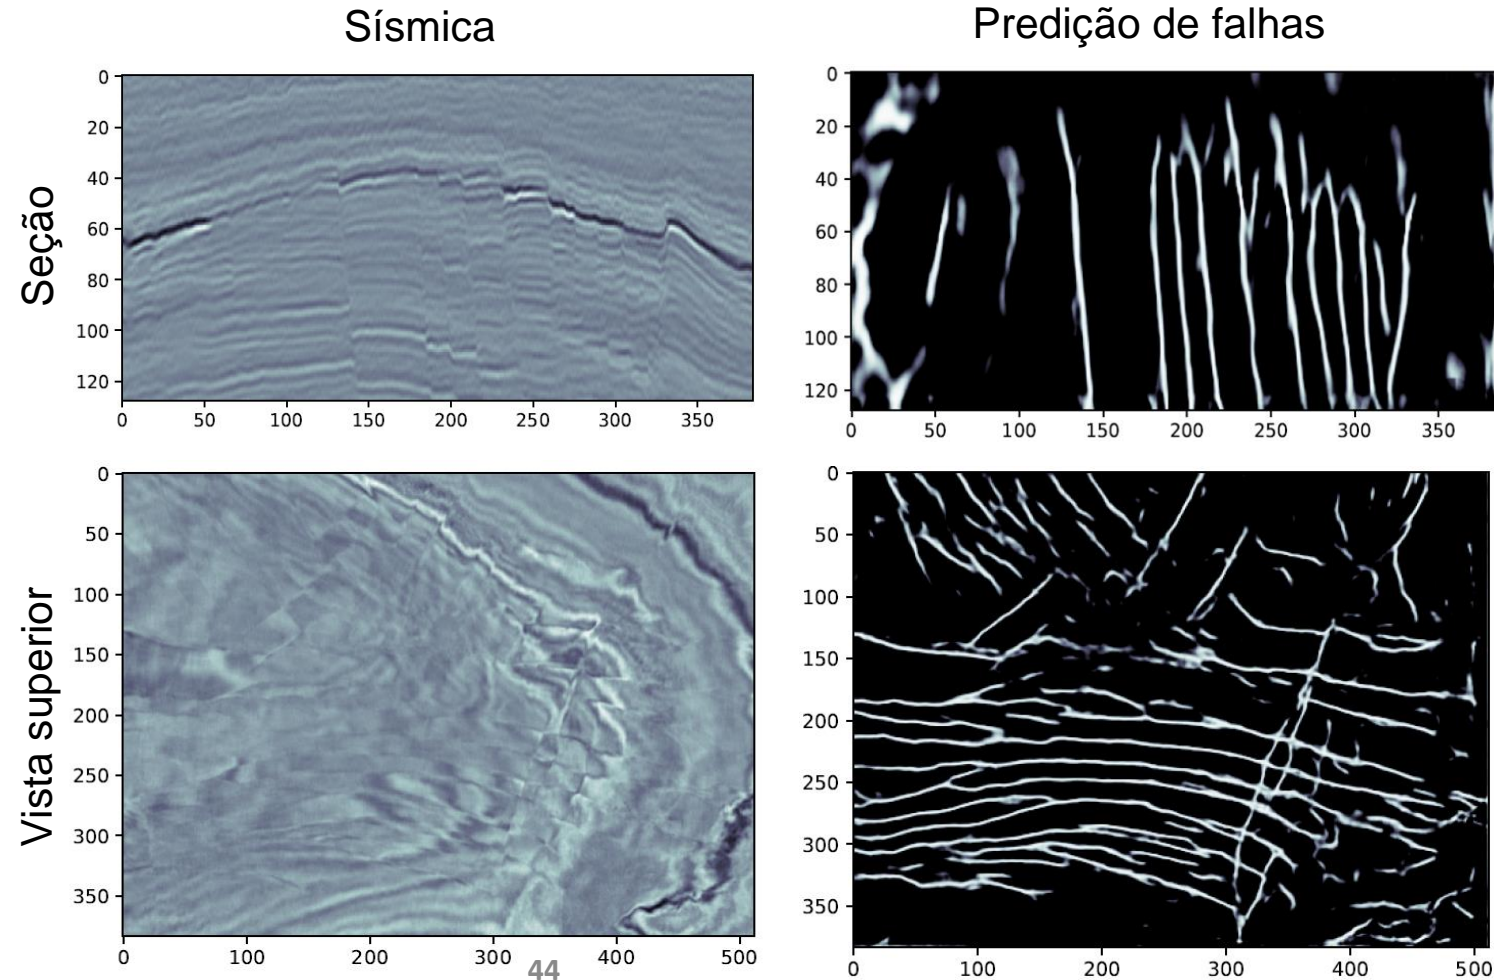
- Predição nos dados sintéticos



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## FaultSeg3D (Wu, et al., 2019)

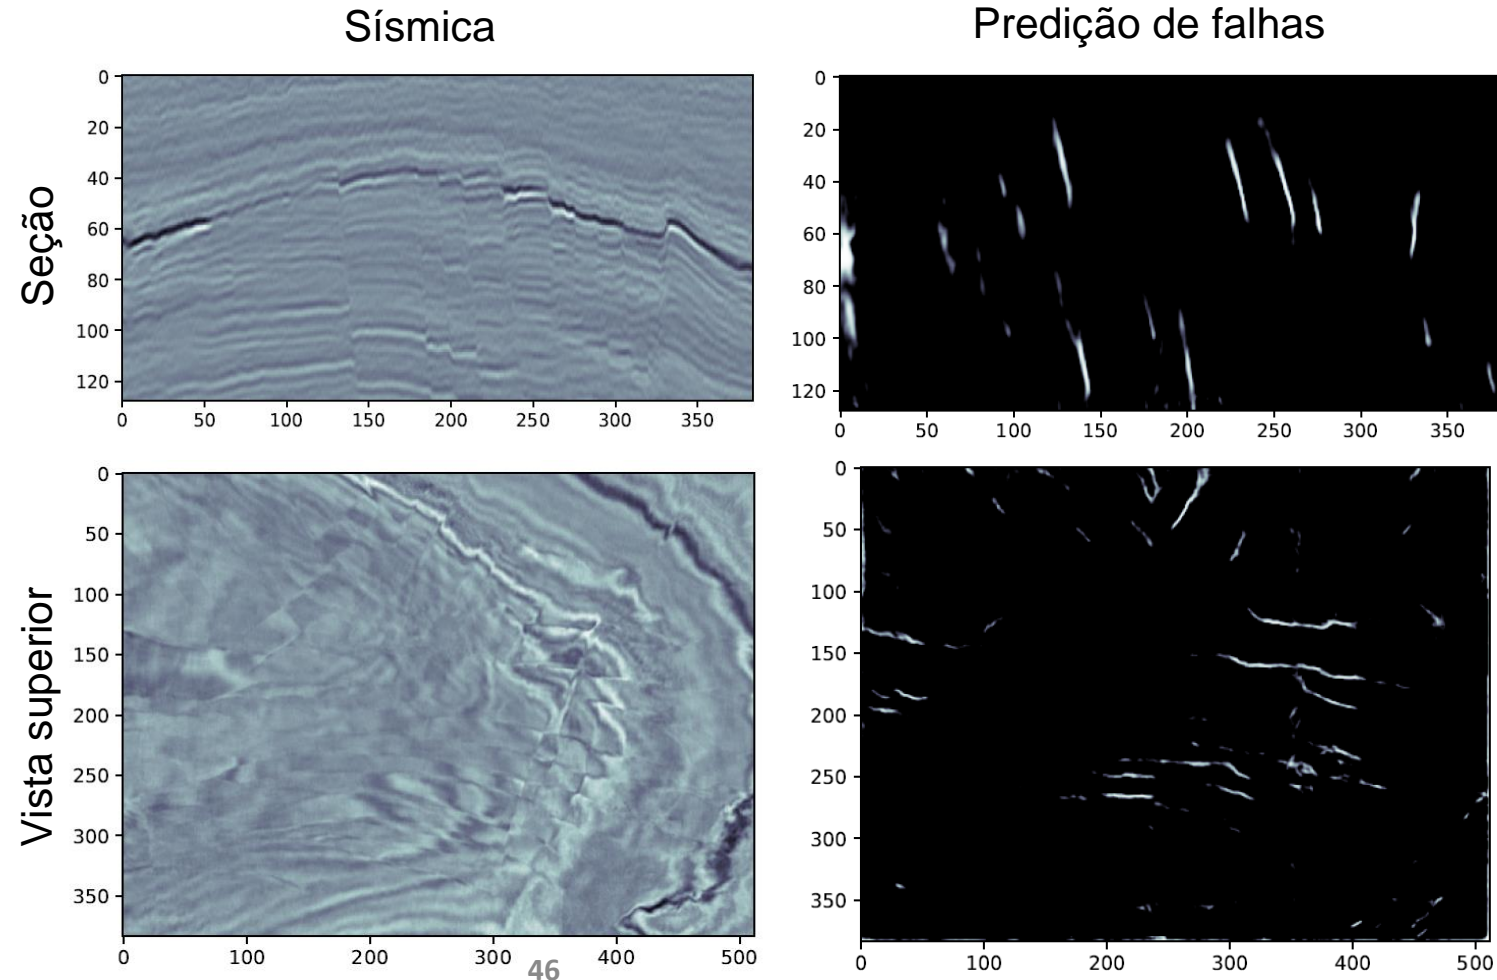
- Predição no Netherlands offshore F3 block



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## FaultSeg3D (Wu, et al., 2019)

- Predição no Netherlands offshore F3 block
- Treinamento com **114 épocas**



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## MD Loss (Dou, Y., et al., 2022)

- **Dou, Y., Li, K., Zhu, J., Li, T., et al., 2022**, MD loss: Efficient training of 3-D seismic fault segmentation network under sparse labels by weakening anomaly annotation: IEEE Transactions on Geoscience and Remote Sensing, 60, 1-14, doi: 10.1109/TGRS.2022.3196810.

- Rede neural baseada em HR-Net (CNN)
- Função custo masked-dice (MD)
  - Permite treinamento com rótulos parciais
  - Robustez a rótulos falso-negativos
- **Código indisponível**


Dados de treinamento:

- **Dados sintéticos 3D** (Xinming Wu)
- **Dados de campo 2D**: Shengli Oilfield Branch (SINOPEC)

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## MD Loss (Dou, Y., et al., 2022)

- HR-Net reduzida



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

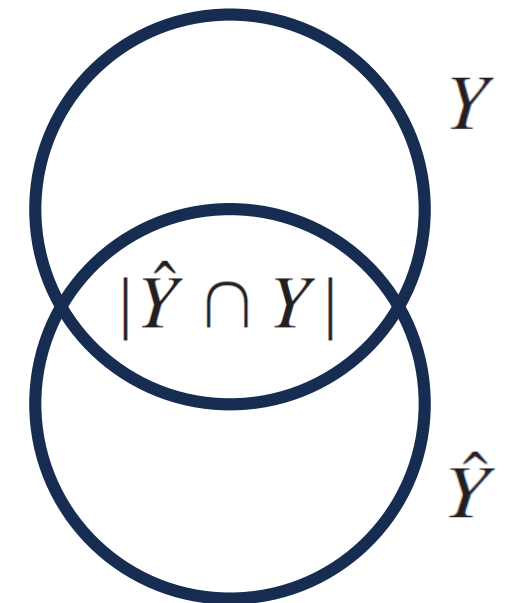
## MD Loss (Dou, Y., et al., 2022)

- Função custo: **masked-dice**
- Função/coeficiente **Dice**
- **Mascaramento**: permite treinamento com rótulos parciais (2D)

$$\mathcal{L}_{\text{dice}} = 1 - \frac{2|\hat{Y} \cap Y|}{|\hat{Y}| + |Y|}$$

$Y$  : rótulo

$\hat{Y}$  : predição






# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING


## MD Loss (Dou, Y., et al., 2022)

- Predição em dado de campo (offshore Louisiana)


Sísmica



FaultSeg3D



MD Loss



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

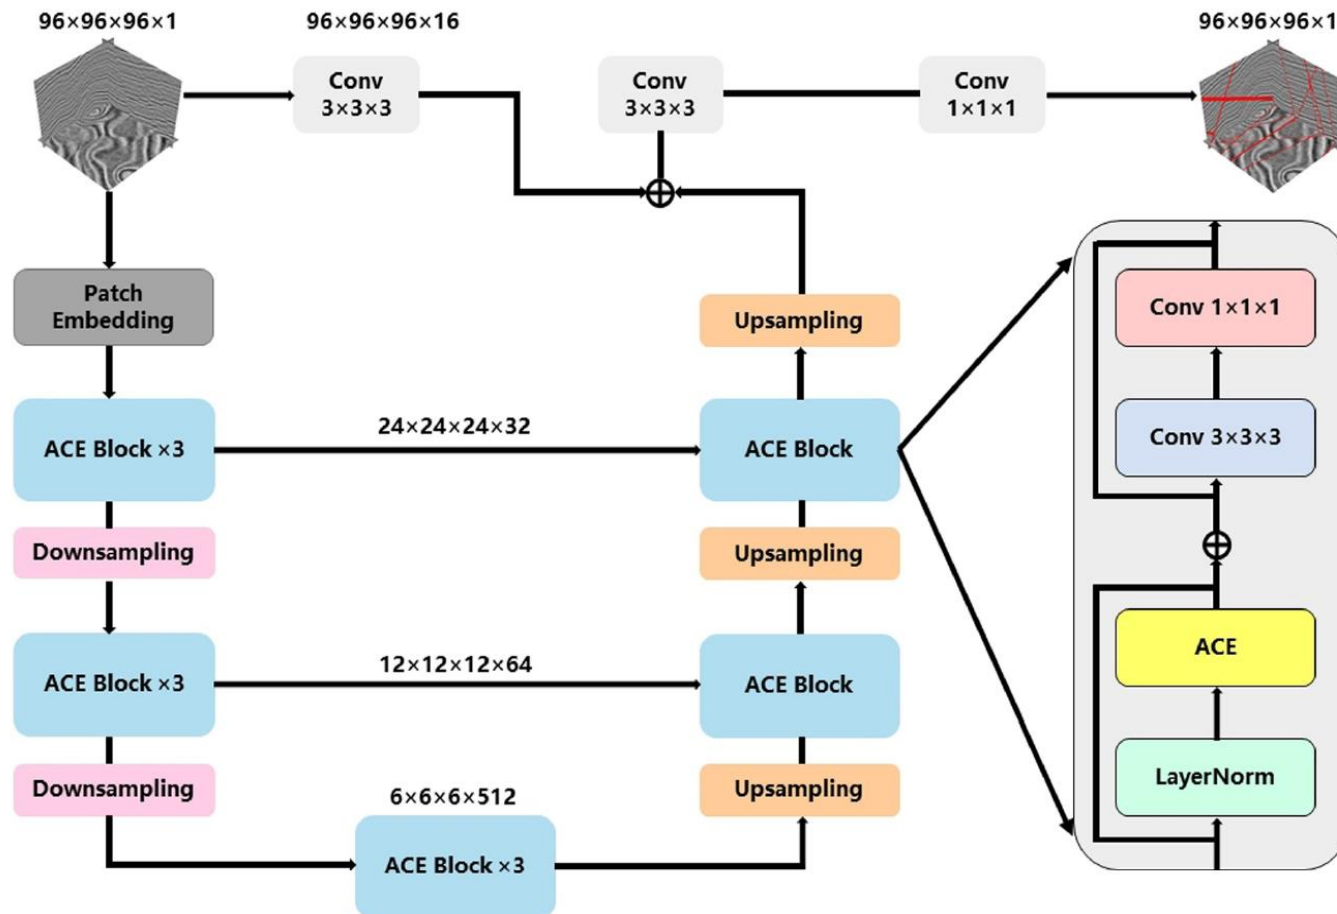
## ResACEUnet (Zu, S., et al., 2024)

- **Zu, S., Zhao, P., Ke, C. and Junxing, C., 2024**, ResACEUnet: an improved transformer Unet model for 3D seismic fault detection: Journal of Geophysical Research: Machine Learning and Computation, 1, e2024JH000232, doi: 10.1029/2024JH000232.
- Utiliza encoder-decoder CNN (U-net) com blocos residuais (res) e de atenção (blocos ACE)
- Função custo que pondera entropia-cruzada e dice
- Dados de treinamento: sintéticos (processo parecido com Wu, X., et al., 2016)

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## ResACEUnet (Zu, S., et al., 2024)

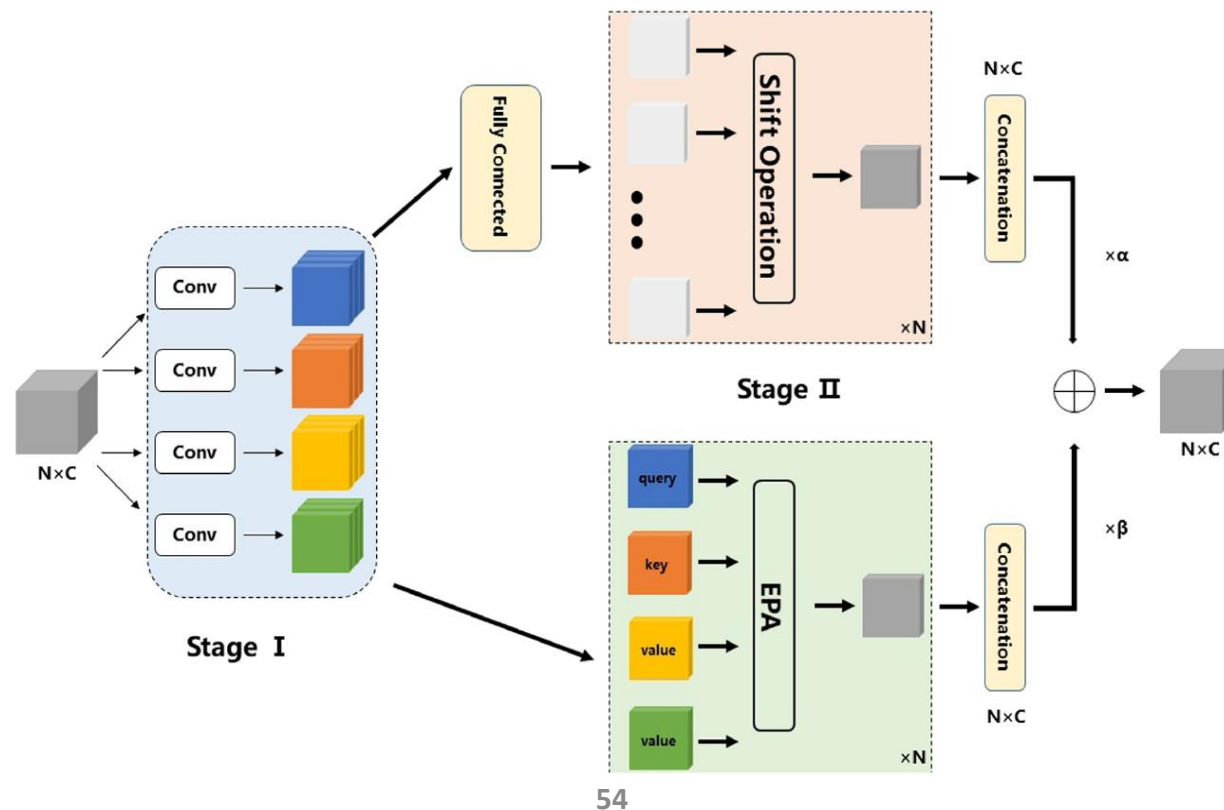
- Rede neural



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## ResACEUnet (Zu, S., et al., 2024)

- Bloco ACE (Attention-convolution with efficient block)






**EPA** (efficient paired-attention block), contém atenção espacial e por canal

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## ResACEUnet (Zu, S., et al., 2024)

- Pós-processamento (teste adicional):
  - Apagar falhas que cabem num volume 21 x 21 x 21




# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING


## ResACEUnet (Zu, S., et al., 2024)

- Predição em dado de campo (offshore Louisiana)


MD Loss



ResACEUnet



ResACEUnet +  
Pós process.



# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## Conclusão

- Trade-off entre falso positivo e falso negativo
  - FaultSeg3D – detecção com muitos artefatos
  - MD Loss – deixa escapar falhas menores
- Dados de treino
  - Sintético: desempenho menor em dados de campo
  - Campo: pouca disponibilidade
- Pós-processamento: ainda a ser aprofundado

# ESTADO DA PRÁTICA: DETECÇÃO DE FALHAS COM DEEP LEARNING

## Perspectivas Futuras

- FaultSeg3D Plus
  - Continuação do trabalho do FaultSeg3D (agosto de 2024)
  - Aprimoramento dos dados sintéticos
  - Métricas mais apropriadas para falhas (Chamfer distance)
- IA-Assisted Fault Extraction do PaleoScan
  - Utiliza encoder-decoder CNN treinada com dados sintéticos
  - Nova versão a ser lançada com aprendizado auto-supervisionado e Transformer



# ESTADO DA PRÁTICA: AGENDA

1. Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado
2. Detecção de falhas com deep learning (DL)
3. **Detecção de canais com DL**
4. Segmentação de feições com foundation models
5. Estimação de RGT com DL

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Análise do estudo que utiliza simulações 3D e deep learning para interpretar canais em imagens sísmicas, avaliando as técnicas e os resultados alcançados (2021)

### **ChannelSeg3D: Channel simulation and deep learning for channel interpretation in 3D seismic images**

Hang Gao<sup>1</sup>, Xinming Wu<sup>1</sup>, and Guofeng Liu<sup>2</sup>

#### **ABSTRACT**

Seismic channel interpretation involves detecting channel structures, which often appear as meandering shapes in 3D seismic images. Many conventional methods are proposed for delineating channel structures using different seismic attributes. However, these methods are often sensitive to seismic discontinuities (e.g., noise and faults) that are not related to channels. We have adopted a convolutional neural network (CNN) method to improve automatic channel interpretation. The key problem in applying the CNN method into channel interpretation is the absence of labeled field seismic images for training the CNNs. To solve this problem, we adopt a workflow to automatically generate numerous synthetic training data sets with realistic channel structures. In this workflow, we first randomly simulate

various meandering channel models based on geologic numerical simulation. We further simulate structural deformation in the form of stratigraphic folding referred to as “folding structures” and combine them with the previously generated channel models to create reflectivity models and the corresponding channel labels. Convolved with a wavelet, the reflectivity models can be transformed into learnable synthetic seismic volumes. By training the designed CNN with synthetic seismic data, we obtain a CNN that learns the characterization of channel structures. Although trained on only synthetic seismic volumes, this CNN shows outstanding performance on field seismic volumes. This indicates that the synthetic seismic images created in this workflow are realistic enough to train the CNN for channel interpretation in field seismic images.

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

- Proposta uma forma de **criação de dados sintéticos**.
- Um algoritmo simula a criação de dados sintéticos.
- Uma CNN é treinada utilizando os dados sintéticos gerados.





Figure 7. Automatically generated seismic images and the corresponding channel labels.

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Os canais sintéticos são gerados em cubos de tamanho 128 x 128 x 128 que são usados como dados de treinamento.

Workflow:

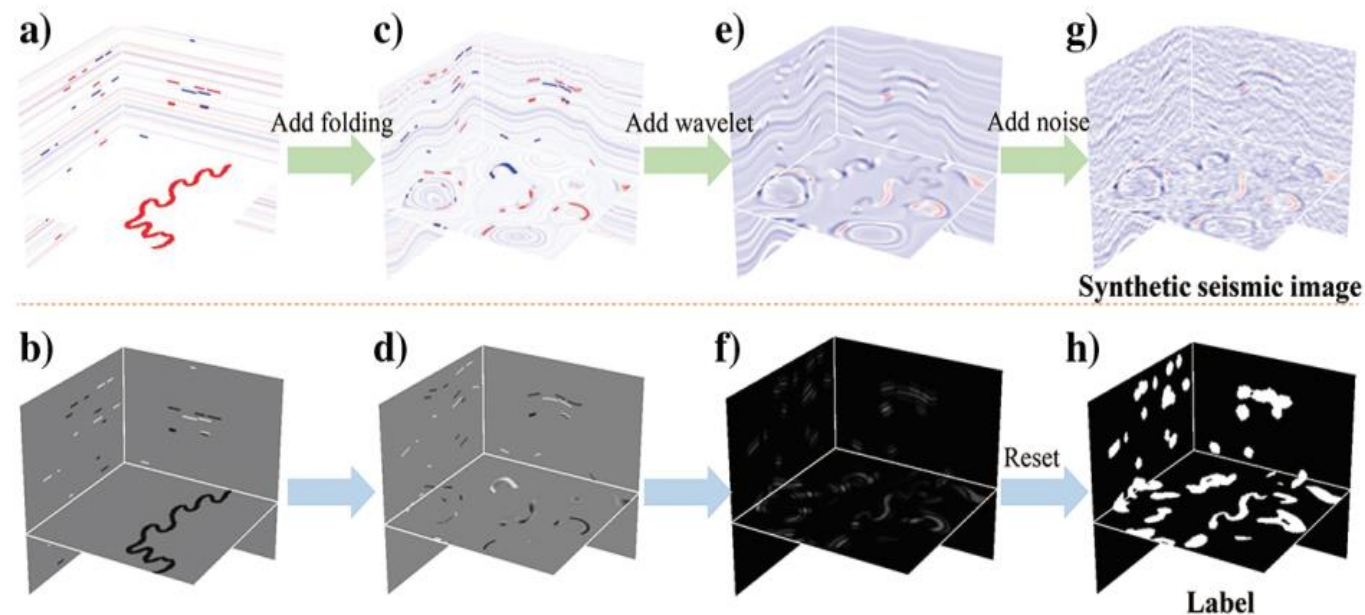


# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Fluxo de geração de dados sintéticos  
(baseado no Meanderpy) (<https://github.com/zsylvester/meanderpy>):

- Inicialmente, um canal reto é gerado.
- O processo de criação de meandros é simulado.
- Uma convolução com wavelet de Ricker é aplicada.
- Ruído é inserido no cubo.
- O cubo é binarizado (valores são arredondados para 0 ou 1).



# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Os autores do artigo forneceram os dados mediante pedido de pesquisador do IPT.

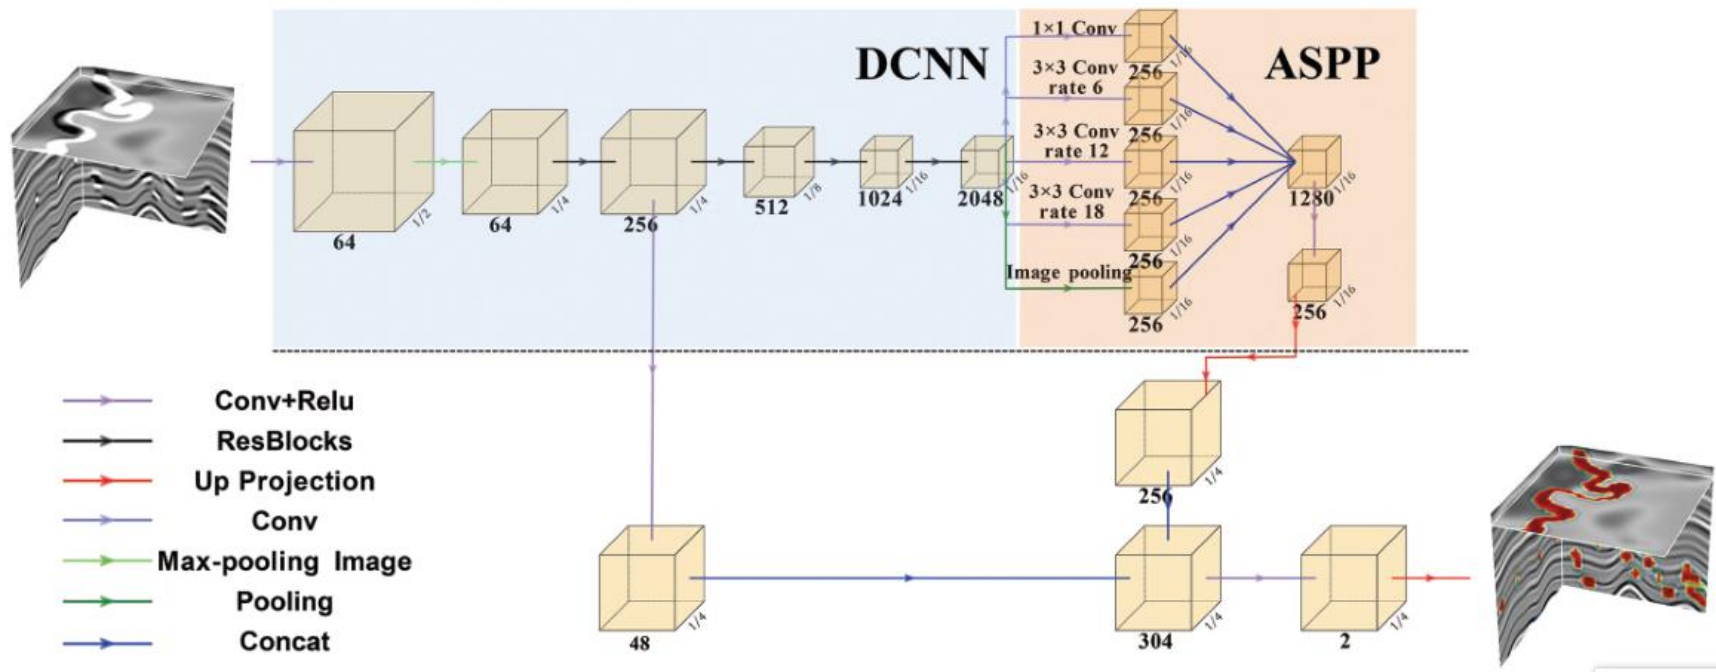
Entre os dados fornecidos estão:

- **Cubos de dados sintéticos e seus respectivos rótulos destacando as regiões com canais (240 amostras).**
  - cubos de tamanho  $128 \times 128 \times 128$ .
  - 200 amostras para treinamento.
  - 40 amostras para validação.
- O modelo de CNN utilizado no trabalho já treinado.
- Dados de campo.

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Modelo utilizado: **DeepLabv3+**




# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS


## Detecção de Canais 3D

- Slices com valores de amplitude de cubos sintéticos:


Slice Cubo



Slice Cubo



Slice Cubo



- Rótulos dos cubos com seus respectivos canais:

Slice Canais



Slice Canais



Slice Canais






# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

Curva de Loss:



# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D

**Table 1. Comparison of different methods on test data sets.**

| Method     | Normalization | Precision (%) | Recall (%)   | mIoU (%)     | F1 score (%) |
|------------|---------------|---------------|--------------|--------------|--------------|
| DeepLabv3+ | Mean-Std      | <b>95.68</b>  | <b>96.41</b> | <b>92.41</b> | <b>96.04</b> |
| DeepLabv3+ | Min-Max       | 95.00         | 95.38        | 91.19        | 95.36        |
| 3D-U-Net   | Mean-Std      | 95.53         | 96.20        | 92.08        | 95.86        |

Note: DeepLabv3+ with Mean-Std achieve better performance on Precision, Recall, mIOU, and F1 score compared with the other methods.


# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Detecção de Canais 3D


Exemplo de Validação em Dados Sintéticos:

- Canais preditos:


Canais Preditos



Canais Preditos



Canais Preditos



- Rótulos de canais:

Canais Reais



Canais Reais



Canais Reais




# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS


## Detecção de Canais 3D

Exemplo de Validação em Dados Sintéticos:

Rótulo



Predição

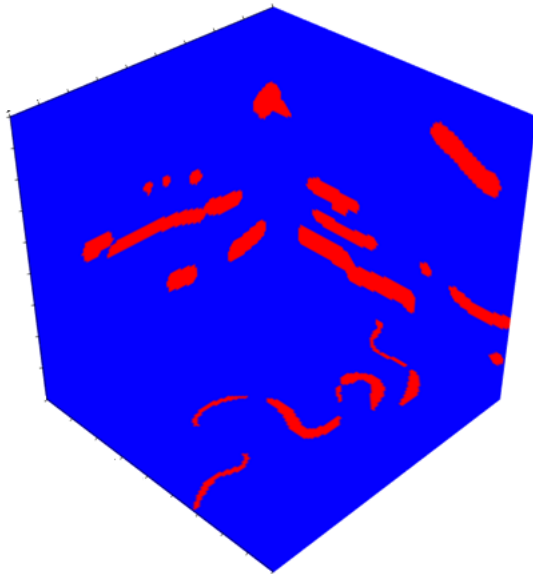


# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS


## Detecção de Canais 3D

Exemplo de Validação em Dados Sintéticos:

Rótulo




Predição




# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

- **Aplicação do Channel Seg 3D em dados reais.**
  - Dois volumes de campo foram utilizados para teste:

Louisiana  
Offshore




Atchafalaya  
Bay



# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Previsão de canais em dados de campo 3D (Louisiana offshore)




O volume de saída apresenta valores de 0 a 1, indicando a probabilidade de canais.

As regiões em vermelho são as regiões de maior probabilidade.

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

Previsão de canais em dados de campo 3D (Atchafalaya Bay)





# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Conclusões

- Há uma ausência de dados reais contendo canais anotados para treinamento, por essa razão, existe a **necessidade de dados sintéticos**.
- Um modelo treinado em dados sintéticos é proficiente em **detectar canais tanto em dados sintéticos quanto reais**, no entanto, muito ruído é detectado em dados reais.
- Foi necessário fazer a predição dos canais para pequenas partes do volume sísmico real por conta de restrições de memória, o que produziu **efeitos de borda**.

# ESTADO DA PRÁTICA: INTERPRETAÇÃO DE CANAIS

## Perspectivas futuras

- A falta de memória resultou em efeitos de borda no resultado. Agora com acesso a maior memória, é possível fazer previsões em volumes maiores.
- Apesar de menos frequentes em relação a detecção de falhas, outros trabalhos exploraram a detecção de canais:
  - **Pham, Dunlap e Fomel (2021)** exploraram detecção de canais em conjunto com outras feições utilizando Grad-CAM para interpretar os resultados alcançado pelo modelo.
  - Planejamos explorar outras abordagens de detecção de canais no futuro.

# ESTADO DA PRÁTICA: AGENDA

1. Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado
2. Detecção de falhas com deep learning (DL)
3. Detecção de canais com DL
- 4. Segmentação de feições com foundation models**
5. Estimação de RGT com DL

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Overview do artigo

- Grupo do Xinming Wu
- Versão não publicada (ArXiv, Dez. 2023)

.geo-ph] 15 Dec 2023

## Seismic Foundation Model (SFM): a new generation deep learning model in geophysics

Hanlin Sheng<sup>1</sup>, Xinming Wu<sup>1\*</sup>, Xu Si<sup>1</sup>, Jintao Li<sup>1</sup>, Sibozhang, and Xudong Duan

<sup>1</sup>School of Earth and Space Sciences, University of Science and Technology of China, Hefei, China.

\*To whom correspondence should be addressed:

E-mail: xinmwu@ustc.edu.cn

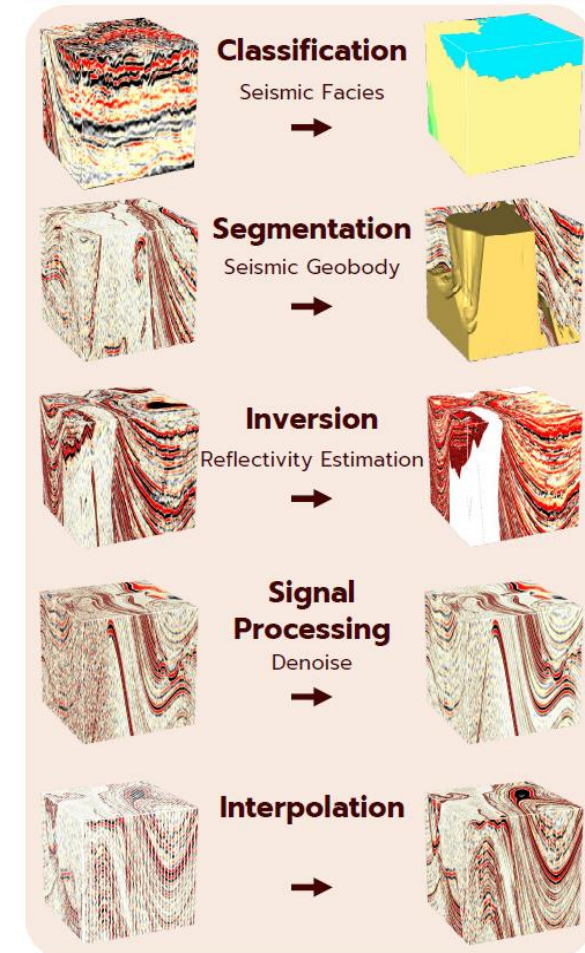
### Abstract

While computer science has seen remarkable advancements in foundation models, which remain underexplored in geoscience. Addressing this gap, we introduce a workflow to develop geophysical foundation models, including data preparation, model pre-training, and adaption to downstream tasks. From 192 globally collected 3-D seismic volumes, we create

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Overview do artigo

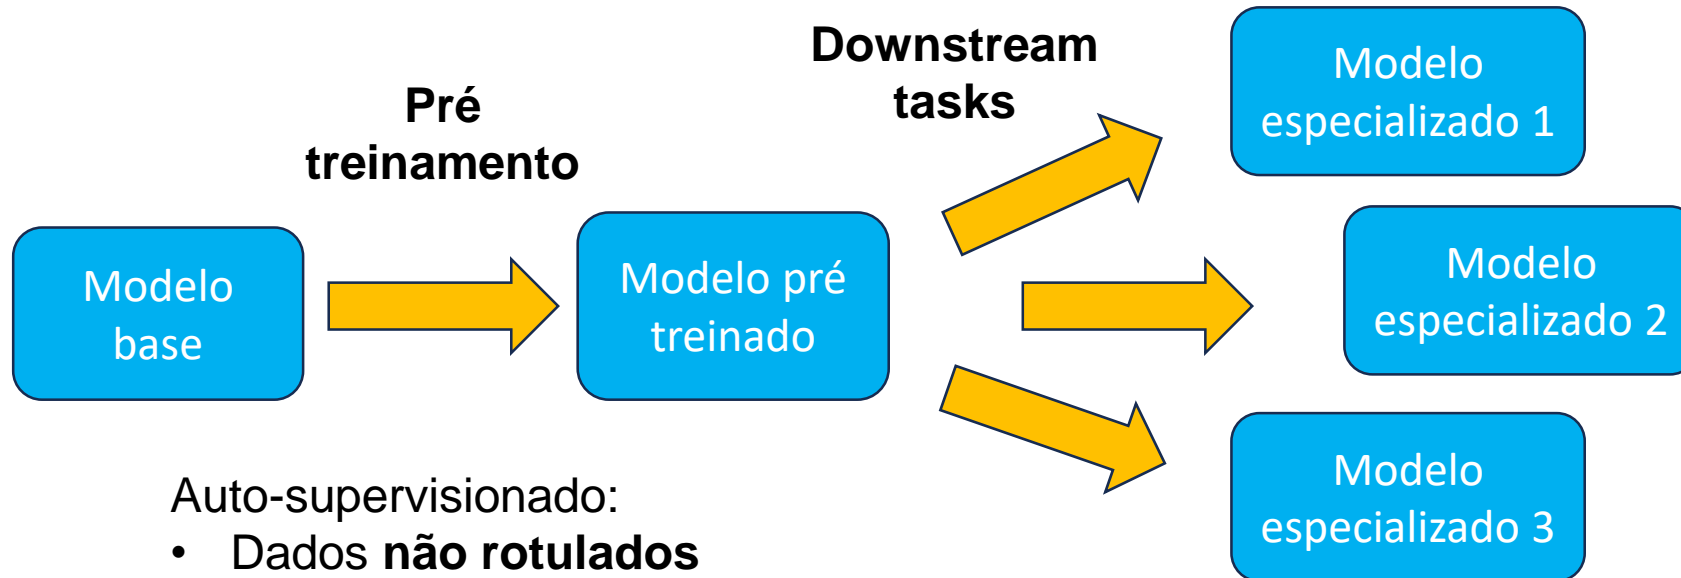
- Foundation model: versatilidade de aplicações
- 5 Aplicações sugeridas no artigo
- Métodos de machine learning
  - VisionTransformer (ViT)
  - CNN
- Trabalha com dados 2D: seções sísmicas



# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Foundation Model

- Duas etapas de treinamento:



Auto-supervisionado:

- Dados **não rotulados**
- Grande quantidade de dados

Supervisionado:

- Dados rotulados
- Menos dados

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Pré-Treinamento

- Abordagem auto-supervisionada: **masked autoencoder (MAE)**
  - Dados são mascarados
  - Objetivo é predizer as partes ocultas
- Pré-treinamento com grande volume de dados
  - No artigo, o modelo é pré-treinado com ~2M imagens

Imagem original



Imagem mascarada



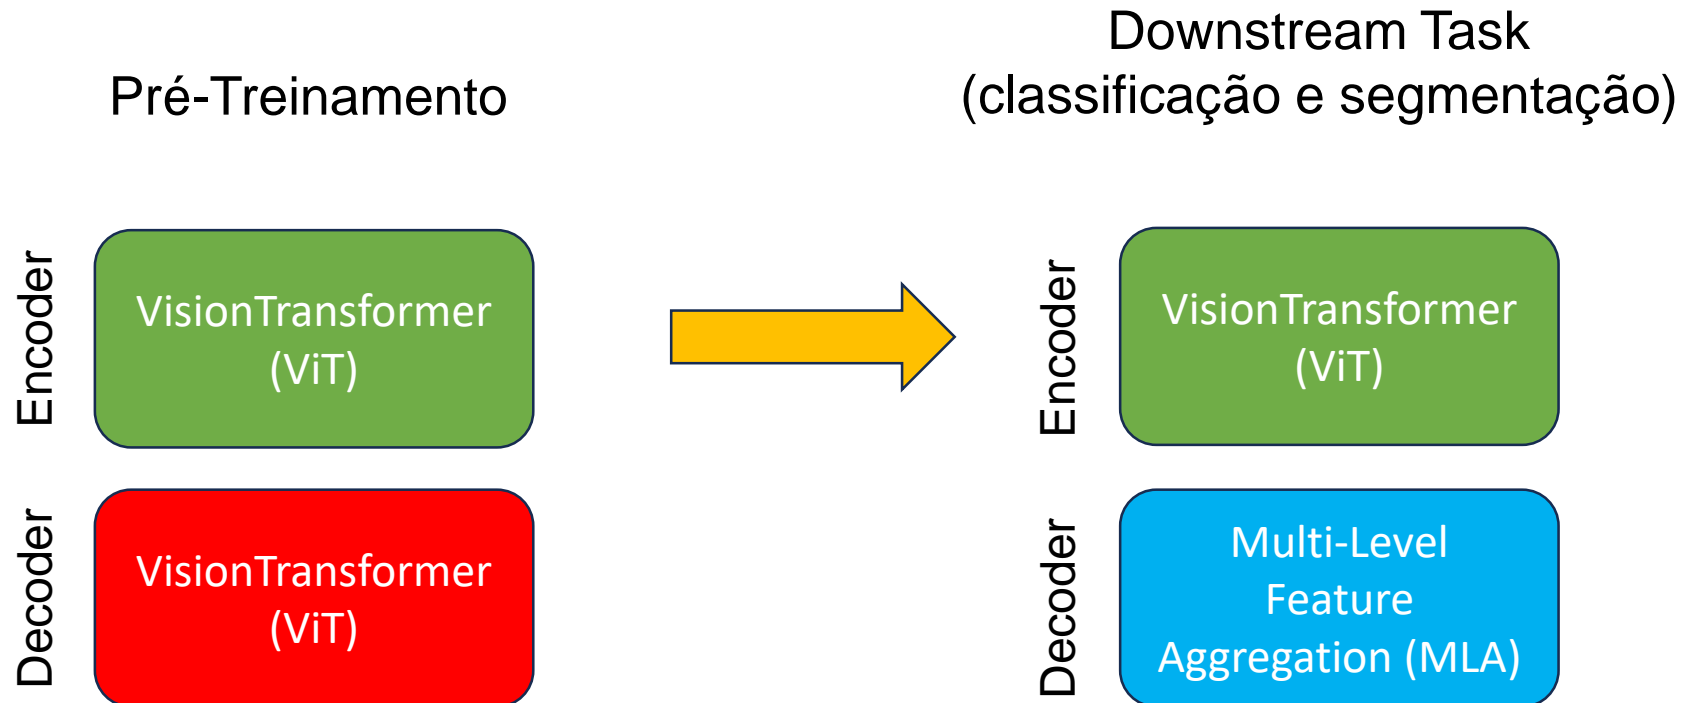


Imagem predita



# ESTADO DA PRÁTICA: FOUNDATION MODELS

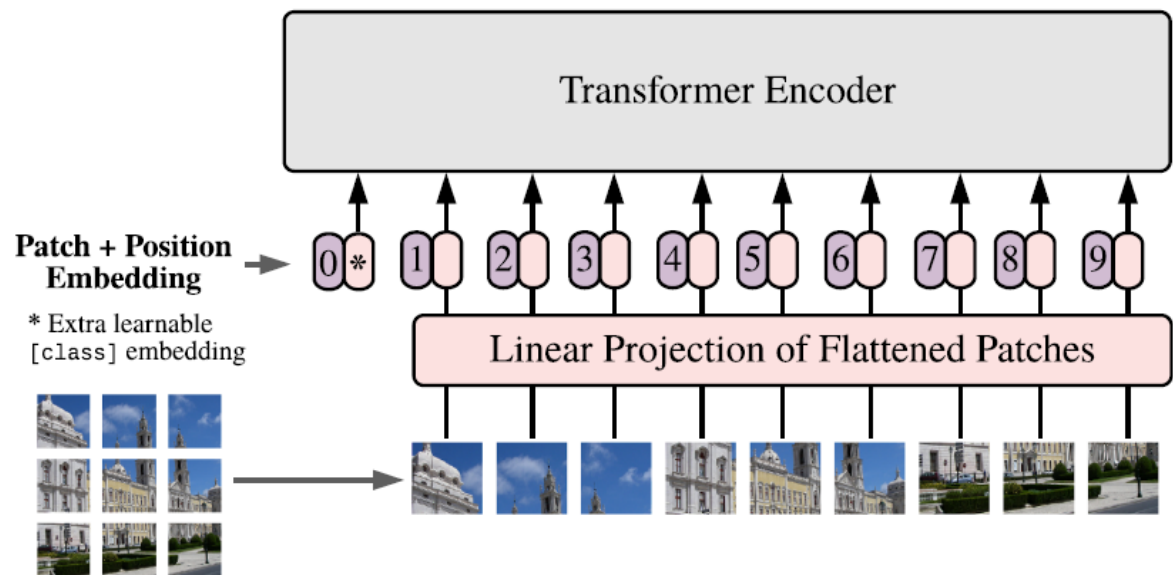
## Composição da rede neural



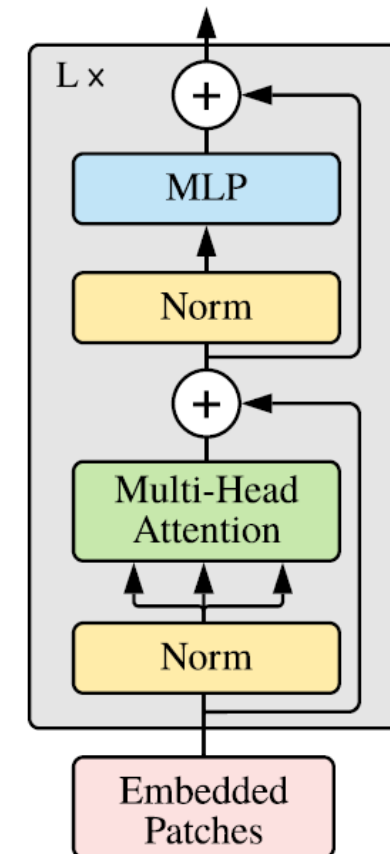


# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Composição da rede neural: VisionTransformer



### Transformer Encoder



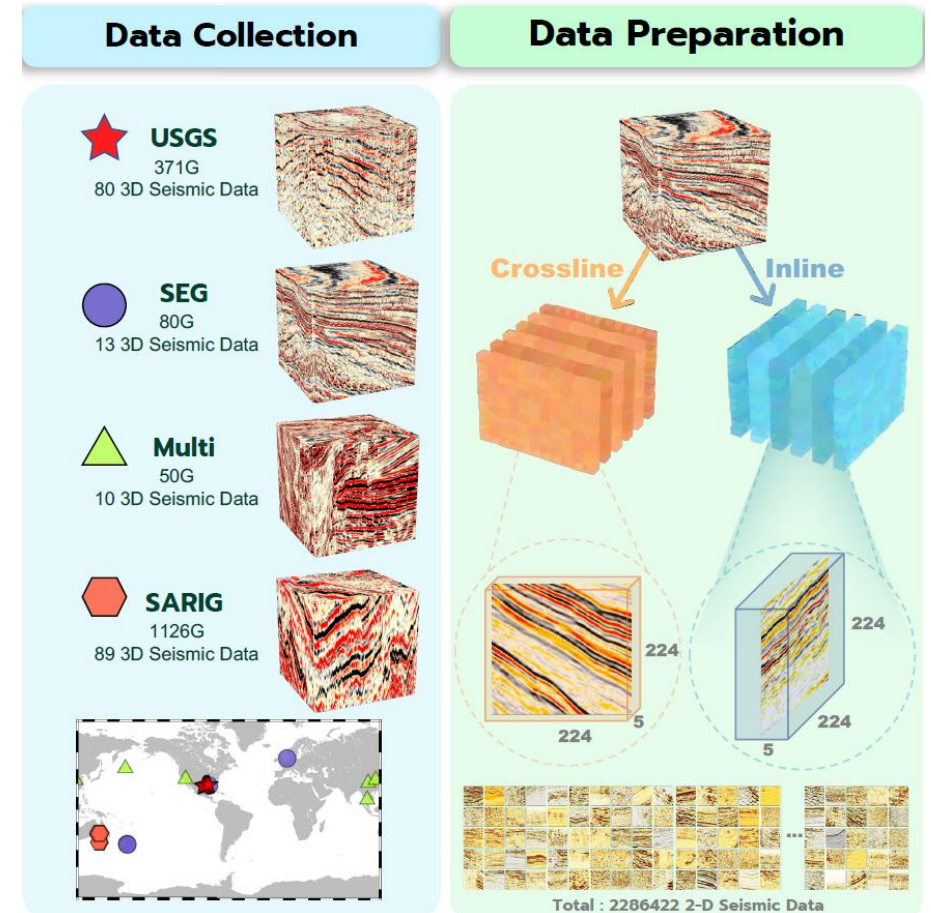
# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Dados de treinamento

- Todos os dados usados no artigo são dados de campo
- Datasets distintos usados no pré-treinamento e em cada especialização

## Pré-Treinamento

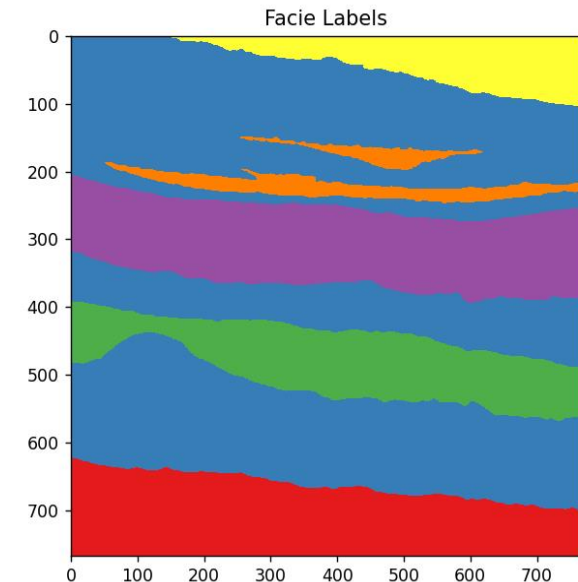


- 192 volumes de dados
- ~ 2M de imagens 224 x 224 (**não rotuladas**)



# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Dados de treinamento (task de classificação de fácies)

- Parihaka Seismic Survey (Nova Zelândia, domínio público)
- Competição da Alcrowd em 2020
- 117 imagens crosslines **rotuladas**, tamanho 768 x 768 (100 para treinamento, 17 para teste)



# ESTADO DA PRÁTICA: FOUNDATION MODELS



## Testes realizados

- Reprodução da task de classificação de fâcies
- Testes com nova downstream task: detecção de falha (testes adicionais)
  - Finetuning com dados sintéticos
  - Finetuning com dados sintéticos e dados de campo

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Classificação de fácies


- Desempenho



# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Classificação de fácies

- Predição



# ESTADO DA PRÁTICA: FOUNDATION MODELS


## Detecção de falhas

- Teste 1: treinamento apenas com dados sintéticos
  - Dados de Wu, X., et al., 2019
  - 500 seções dos dados 3D (400 treino, 100 teste)
  - Imagens 128 x 128
- Teste 2: treinamento com dados sintéticos e de campo
  - Dados de Wu, X., et al., 2019 (1000 seções)
  - Thebe Gas Field da Carnarvan Basin, noroeste da Australia (3921 seções)
  - Imagens 224 x 224

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Detecção de falhas

- Exemplos dos dados da Thebe Gas Field



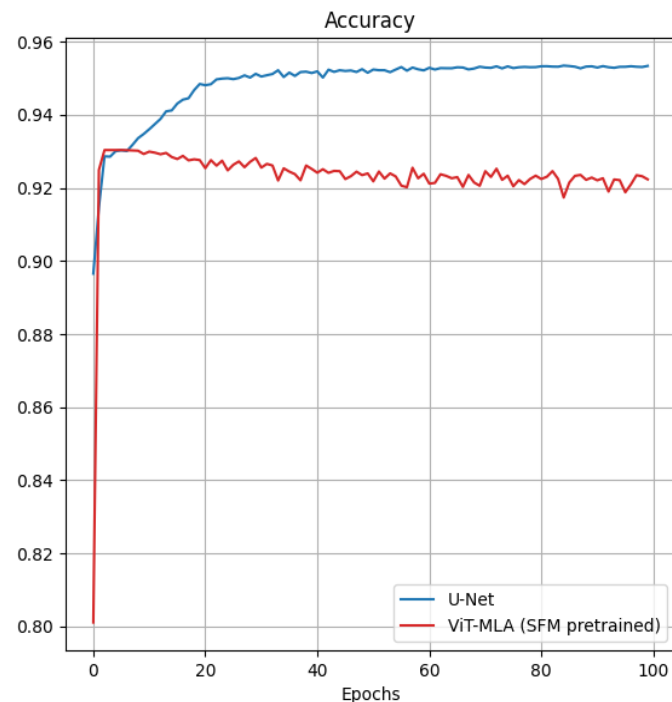


# ESTADO DA PRÁTICA: FOUNDATION MODELS


## Detecção de falhas

- Curva de desempenho

Teste 1:  
Dados  
sintéticos



Teste 2:  
Dados  
sintéticos  
+  
Dados de  
campo




# ESTADO DA PRÁTICA: FOUNDATION MODELS


## Detecção de falhas (Teste 1: treino com dados sintéticos)

- Predição no Netherlands F3


Sísmica




U-Net



SFM



FaultSeg3D




# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Detecção de falhas (Teste 2: treino com dados sintéticos e de campo)

- Predição no Netherlands F3


Sísmica




U-Net



SFM



FaultSeg3D



# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Outros Trabalhos

- Artigo recente (março de 2024) sugere que transformer (ViT) não é bom para detecção de falhas

Expert Systems With Applications 249 (2024) 123617



Contents lists available at ScienceDirect

Expert Systems With Applications

journal homepage: [www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)



### 3D seismic Fault Detection via Contrastive-Reconstruction Representation Learning<sup>☆</sup>

Yimin Dou, Kewen Li\*

*China University of Petroleum (East China), School of Computer Science and Technology, Qingdao, 266580, China*

#### ARTICLE INFO

##### Keywords:

Seismic data  
Seismic fault  
Image segmentation  
Pretrained Foundation Models (PFMs)  
Contrastive learning  
Representation learning  
Self-supervised learning

#### ABSTRACT

Fault detection is a critical step in structural modeling and characterizing reservoirs. 3D seismic fault labeling is almost impossible to obtain, while networks trained on synthetic fault data have limited generalization to real data. We use self-supervised representation learning to enable networks to learn seismic field data features during pre-training, improving generalization. However, widely popular ViT/SwinViT-based methods cannot capture low-level fault features well. CNN-based have limited capability in transferring to downstream tasks. Tackle this, we designed the Tiny Self-Attention and extensively embedded it into the HRNet. It merges the advantages of convolutional and self-attention, allowing for in-depth learning of seismic representation information during the representation learning phase, thus achieving better inter-class separation in downstream tasks. We crafted two proxy tasks. The contrastive task aims to minimize the projected feature distance of overlapping areas from two distinct views. To tackle the issue of memory overflow and training suspension


# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Outros Trabalhos

- Artigo recente (março de 2024) sugere que transformer (ViT) não é bom para detecção de falhas

Expert Systems With Applications 249 (2024) 123617

Contents lists available at ScienceDirect



change vertically. The task of detecting gradient changes in images is called edge detection, which focuses more on the extraction of low-level features. However, the most popular reconstructive visual pre-training framework, MAE, based on Vision Transformer (ViT) (Dosovitskiy et al., 2020), may not be suitable for fault detection tasks. The reason is that ViT focuses on the extraction of more abstract semantic features, ignoring low-level features, and directly uses fully connected layers with shared parameters to divide the image into patches (such as

3D seismic Fault Detection via Representation Learning<sup>☆</sup>

Yimin Dou, Kewen Li\*

China University of Petroleum (East China), School of Computer Science and Technology, Qingdao, 266580, China

ARTICLE INFO

Keywords:  
Seismic data  
Seismic fault  
Image segmentation  
Pretrained Foundation Models (PFMs)  
Contrastive learning  
Representation learning  
Self-supervised learning

we consider using massive field data for representation learning to establish a pre-trained model and transfer field data information to downstream tasks, but this faces three challenges. First, the mainstream ViT method has difficulty extracting low-level features, which may be unsuitable for fault detection tasks, while convolution-based methods have weaker capabilities to transfer to downstream tasks. Second, the

information during the representation learning phase, thus achieving better inter-class separation in downstream tasks. We crafted two proxy tasks. The contrastive task aims to minimize the projected feature distance of overlapping areas from two distinct views. To tackle the issue of memory overflow and training suspension

# ESTADO DA PRÁTICA: FOUNDATION MODELS

## Conclusões

- Foundation model: base versátil para uma gama de aplicações
- Treinamento auto-supervisionado: melhora desempenho usando dados de treinamento **não-rotulados**
- Permite complementar treinamento com dados de campo
- SFM tem desempenho melhor que modelos da literatura (U-Net) em algumas tasks (fácies), mas em outras fica equiparável (falhas)

# ESTADO DA PRÁTICA: AGENDA

1. Detecção de falhas com atributos e machine learning (ML) e com aprendizado não supervisionado
2. Detecção de falhas com deep learning (DL)
3. Detecção de canais com DL
4. Segmentação de feições com foundation models
5. **Estimação de RGT com DL**

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Overview do Artigo

- Grupo do Xinming Wu
- Publicado em 2021



## JGR Solid Earth



RESEARCH ARTICLE  
10.1029/2021JB021882

**Special Section:**  
Machine learning for Solid Earth observation, modeling and understanding

### Key Points:

- We propose an encoder-decoder network with attention mechanism to estimate relative geologic time (RGT) volumes from 3D seismic images
- We train the network with a criterion of structural similarity which enables the network capture seismic structural interdependences
- Our method can deal with large 3D seismic images and estimate RGT volumes from which all horizons and faults can be automatically extracted

## Deep Relative Geologic Time: A Deep Learning Method for Simultaneously Interpreting 3-D Seismic Horizons and Faults

Zhengfa Bi<sup>1</sup>, Xinming Wu<sup>1</sup> , Zhicheng Geng<sup>2</sup> , and Haishan Li<sup>3</sup>

<sup>1</sup>School of Earth and Space Sciences, University of Science and Technology of China, Hefei, China, <sup>2</sup>Bureau of Economic Geology, University of Texas at Austin, Austin, TX, USA, <sup>3</sup>Research Institute of Petroleum Exploration and Development-Northwest (NWGI), Lanzhou, China

**Abstract** Extracting horizons and detecting faults in a seismic image are basic steps for structural interpretation and important for many seismic processing schemes. A common ground of the two tasks is to analyze seismic structures and they are related to each other. However, previously proposed methods deal with the tasks independently, and challenge remains in each of them. We propose a volume-to-volume neural network to estimate a relative geologic time (RGT) volume from a seismic volume, and this RGT volume is further used to simultaneously interpret horizons and faults. The network uses U-shaped framework with attention mechanism to systematically aggregate multi-scale information and automatically highlight informative features, and achieves high prediction accuracy with affordable computational costs. To train the network, we build thousands of 3-D noisy synthetic seismic volumes and corresponding RGT volumes with realistic and various structures. We introduce a loss function based



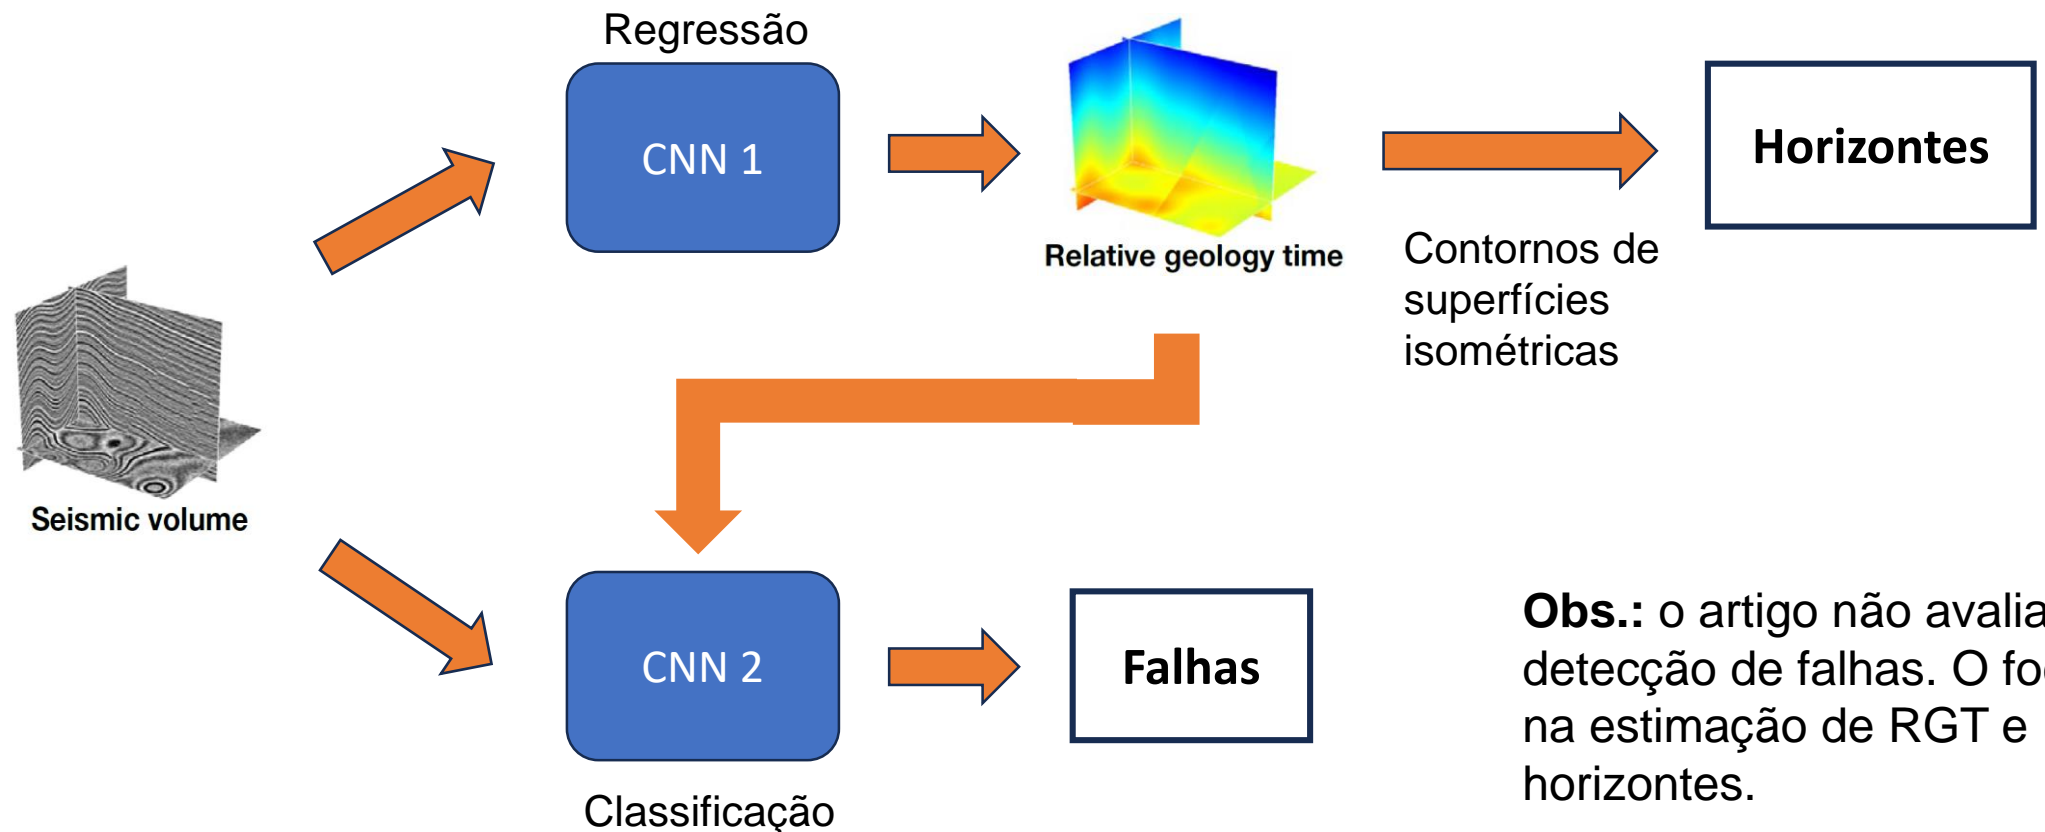
# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Overview do Artigo

- Proposta de estimar três informações geológicas:
  - RGT, horizontes e falhas
- Treinamento com dados "semi-sintéticos"
- Método: CNN (U-Net) com modificações

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL


## Fluxo do processamento



**Obs.:** o artigo não avalia a detecção de falhas. O foco é na estimação de RGT e horizontes.

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Rede Neural Proposta



- Framework U-Net
- Encoder com **módulos squeeze-and-excite (SE) e residual** (atenção por canal)
- Decoder com **módulos de atenção** (atenção espacial)

- Número de parâmetros: **56.6M**
- Para comparação:
  - FaultSeg3D: **1.4M**
  - U-Net (2D): **34.5M**

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Funções custo de treinamento

- Multi-scale Structure Similarity (SSIM) - para **regressão**

$$\mathcal{L}_{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)},$$

- Balanced Cross-Entropy – para **classificação**

$$\mathcal{L}_{Fault} = -\beta \sum_{i=1}^N \mathbf{y}_i \log(\mathbf{x}_i) - (1 - \beta) \sum_{i=1}^N (1 - \mathbf{y}_i) \log(1 - \mathbf{x}_i),$$

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Funções custo de treinamento

- Multi-scale Structure Similarity (SSIM) - para **regressão**

$$\mathcal{L}_{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)},$$

Covariância entre janela x (predição) e janela y (rótulo)

- Balanced Cross-Entropy – para **classificação**

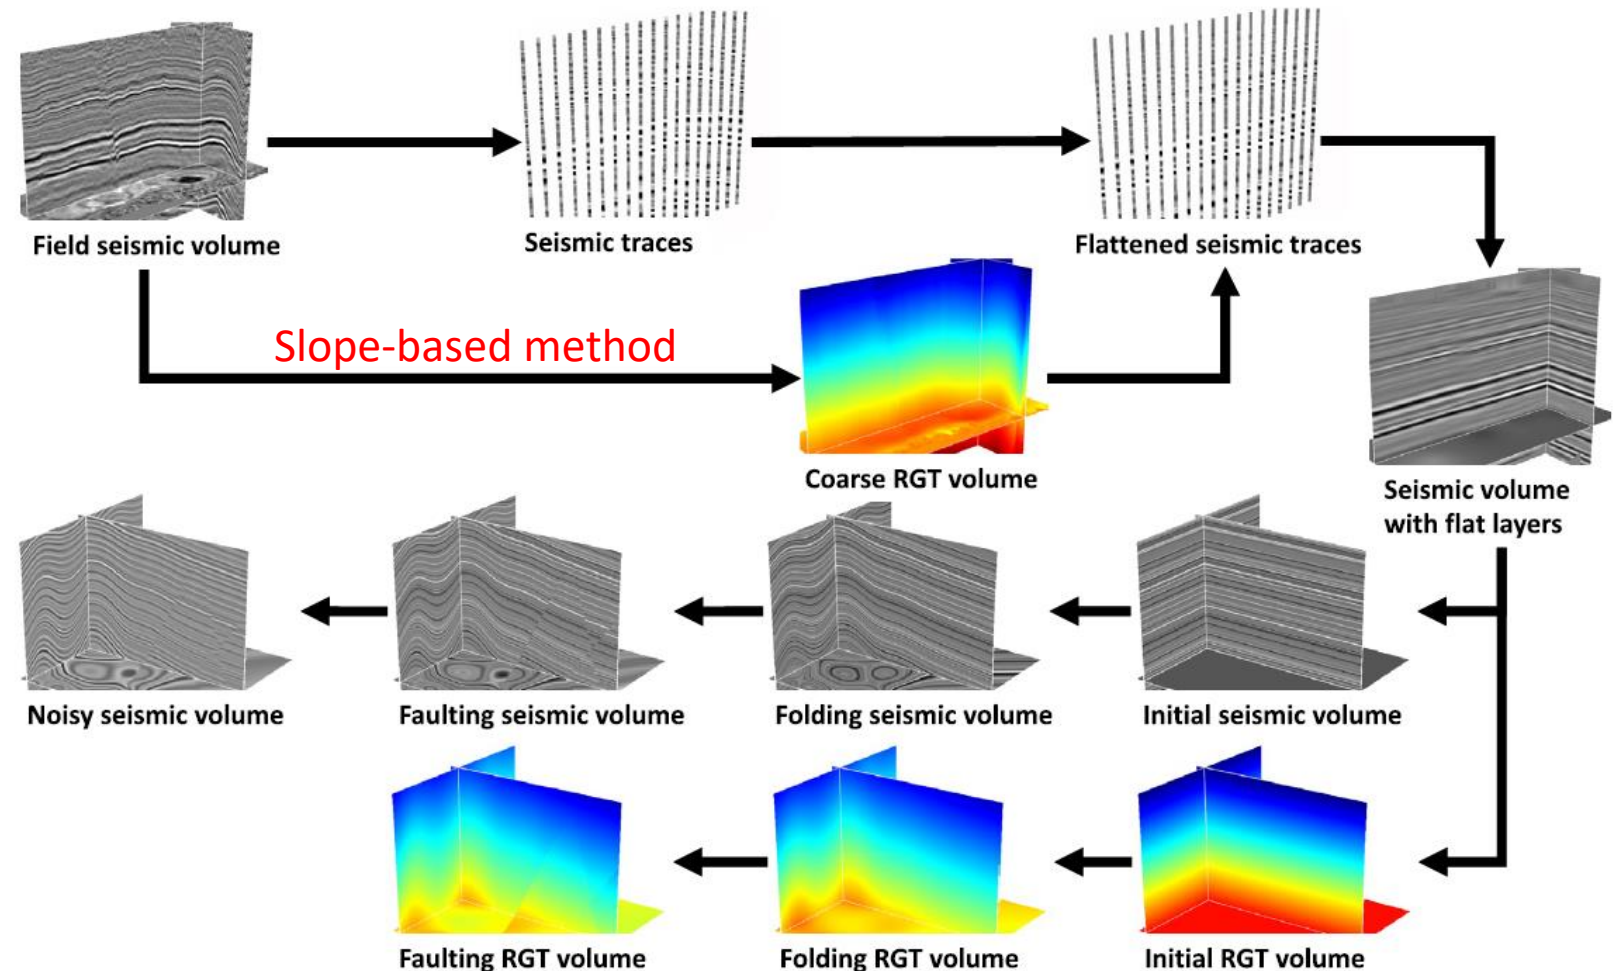
$$\mathcal{L}_{Fault} = -\beta \sum_{i=1}^N \mathbf{y}_i \log(\mathbf{x}_i) - (1 - \beta) \sum_{i=1}^N (1 - \mathbf{y}_i) \log(1 - \mathbf{x}_i),$$

# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Dados do Artigo

Treino e teste com dados 3D "**semi-sintéticos**":




- Construído com traços de dados de campo (não informa de onde)
- RGT estimados de dados de campo
- Dobramentos e falhas sintéticas



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Dados do Artigo

- Dados "semi-sintéticos" (treino e teste)
  - 400 volumes distintos (tamanho: 256 x 256 x 128)
  - Data augmentation: flip e rotação --> **2800 volumes** efetivos
  - 90% treino, 10% teste



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução



- Adaptações:
  - Tamanho de input: (256 x 256 x 128) para (96 x 96 x 96)
  - Tamanho de rede neural: 56M para 30M parâmetros
- Treino e teste para estimação de RGT
- Treino e teste para detecção de falha



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução (RGT)

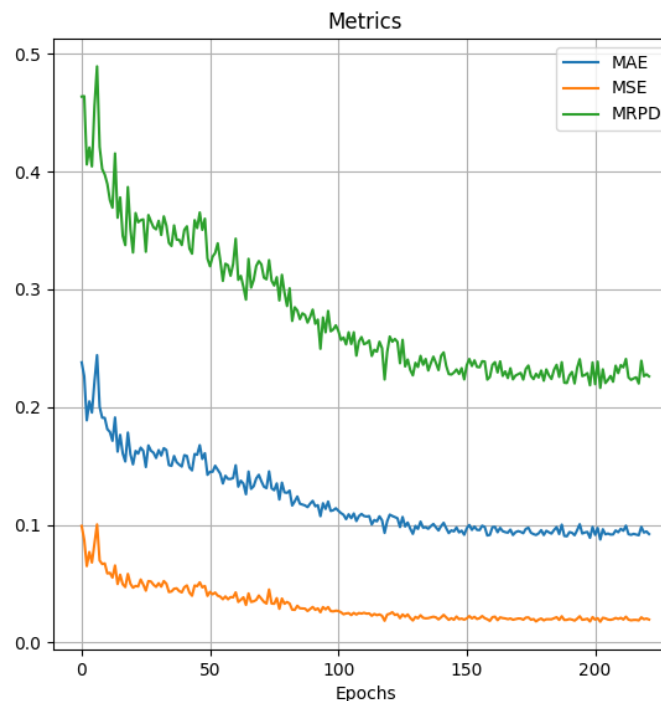

- Curvas de desempenho



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução (RGT)

- Curvas de desempenho



- Comparação com desempenho do artigo (métricas em regime):

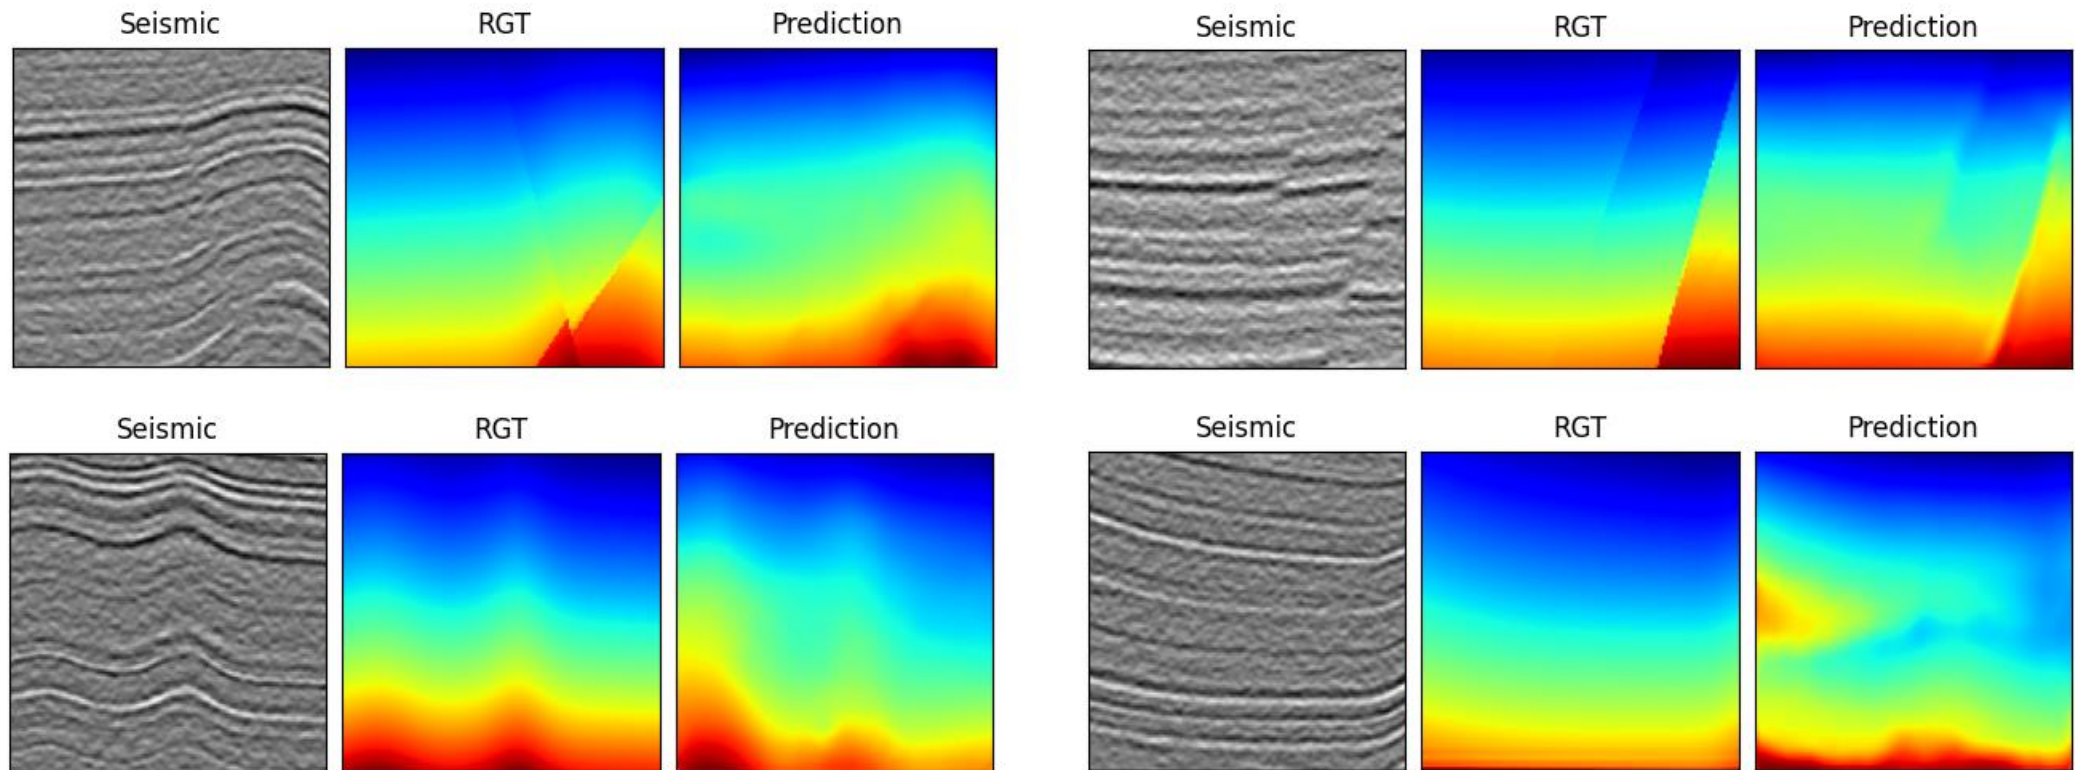
| Métrica | Artigo | Reprod. |
|---------|--------|---------|
| SSIM    | 0.003  | 0.02    |
| MSE     | 0.002  | 0.025   |
| MAE     | 0.011  | 0.1     |
| MRPD    | 0.036  | 0.23    |



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução (RGT)



- Amostras de predição (dados sintéticos)



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução (Falhas)

- Curvas de desempenho



Mixed dataset


Default dataset

- **Mixed Dataset:** incluiu dados do Xinming Wu para treinamento
- **RGT:** utilizou RGT na entrada da CNN, como proposto no artigo


# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Testes de Reprodução (Falhas)


- Predição no F3




FaultSeg3D




Default




Mixed Dataset



Fullsize



Mixed Dataset w/ Dropout



# ESTADO DA PRÁTICA: ESTIMAÇÃO DE RGT COM DL

## Conclusão

- Testes não alcançaram o mesmo desempenho apresentado no artigo (em cerca de 10 vezes)
- Perspectivas futuras: outros artigos sobre RGT com deep learning
  - **Yang, J., Wu, X., Bi, Z., Geng, Z., 2023**, A multi-task learning for relative geologic time, horizons, and faults with prior information and transformer: IEEE Trans. Geosci. Remote Sensing, vol 61.
  - **Di, H., Li, Z., Abubakar, A., 2022**, Using relative geologic time to constrain convolutional neural network-based seismic interpretation and property estimation: Geophysics, vol. 87, no. 2, IM25-IM35.

# Obrigado!



[linkedin.com/school/iptsp/](https://www.linkedin.com/school/iptsp/)



[instagram.com/ipt\\_oficial/](https://www.instagram.com/ipt_oficial/)



[youtube.com/@IPTbr/](https://www.youtube.com/@IPTbr/)

[www.ipt.br](http://www.ipt.br)

