



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CENTRO DE MATEMÁTICA E CIÊNCIAS NATURAIS
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE GEOLOGIA

Davi de Souza Cardoso

**Interpretação Sísmica de Falhas Assistida por Aprendizado de Máquina no
Intervalo Pré-Sal no Campo de Gato do Mato (Bacia de Santos)**

Rio de Janeiro

2025

Davi de Souza Cardoso

**Interpretação Sísmica de Falhas Assistida por Aprendizado de Máquina no
Intervalo Pré-Sal no Campo de Gato do Mato (Bacia de Santos)**

Trabalho Final de Curso de Graduação em
Geologia do Instituto de Geociências,
Universidade Federal do Rio de Janeiro –
UFRJ, apresentado como requisito necessário
para obtenção do grau de Geólogo.

Orientador:

Prof. Dr. Leonardo Fonseca Borghi de
Almeida (Depto. Geologia, IGEO/UFRJ)

Coorientador:

M.Sc. Michael George Lowsby (Petrobras)

Rio de Janeiro

2025

FICHA CATALOGRÁFICA AQUI

Davi de Souza Cardoso

**Interpretação Sísmica de Falhas Assistida por Aprendizado de Máquina no
Intervalo Pré-Sal no Campo de Gato do Mato (Bacia de Santos)**

Trabalho Final de Curso de Graduação em
Geologia do Instituto de Geociências,
Universidade Federal do Rio de Janeiro –
UFRJ, apresentado como requisito necessário
para obtenção do grau de Geólogo.

Rio de Janeiro, XX de XXXXXXXX de 2025.

Prof. Dr. Leonardo Fonseca Borghi de Almeida (UFRJ)

Prof. Dr. Francisco Manoel Wohnrath Tognoli (UFRJ)

M.Sc. Edimar Perico (Petrobras)

“Portanto, meus amados irmãos, sede firmes e constantes, sempre abundantes na obra do Senhor, sabendo que o vosso trabalho não é vão no Senhor.”

1 Coríntios 15:58, ARC

AGRADECIMENTOS

Agradeço a Deus, antes de tudo, que me entregou a geologia como profissão, paixão e ministério. Ele me capacitou e me manteve firme e constante. A Ele toda honra e glória.

Aos meus amados pais, Carlos e Eliane, e minha irmã, Beatriz, que me sustentaram de todas as maneiras possíveis durante o período da graduação. Espero honrar todo o esforço que fizeram por mim. Esta conquista também é de vocês. Amo vocês pra sempre.

À minha querida Rebecca, minha pessoa favorita. Ter você ao meu lado é a certeza de que terei sempre alguém para me dar suporte e me incentivar. Quero fazer o mesmo por você, quantas vezes forem necessárias. Te amo demais.

Especialmente agradeço aos meus avós, Elza, Maurício, Zilézia e José Carlos. Sou fruto do trabalho de vocês. Aos meus familiares, sejam Souza ou Cardoso - ou Moreira.

Aos meus amigos, irmãos e irmãs da geologia, Amon, Alessandra, Bernardo, Carol, Casado, Diego, Elson, Gisella, João, Jola, Laura, Léo, Marina, Marcelle, Olívia, Pedro Van, Tomaz e Viviane; essa caminhada seria impossível sem vocês. Geologia não se faz sozinho.

À Universidade Federal do Rio de Janeiro, minha eterna casa, que me propiciou um ensino público, gratuito e de qualidade. Que continue e se aprimore com o passar dos anos.

Aos professores do Departamento de Geologia da UFRJ que, com muita competência, me emprestaram seus conhecimentos e me fizeram chegar onde estou hoje.

A cada funcionário da UFRJ, que prestaram seus serviços com excelência para que eu pudesse me graduar. Especialmente cito as secretárias Anadja e Bete e os motoristas Edi “Speed” Naldo, Vanderlei, Damião e o botafoguense Edu. Já tenho saudades da kombi.

À Petrobras, por todos os recursos investidos para que o seu programa de estágio fosse - e, de fato, é - um programa formador de profissionais competentes. Aos meus colegas do CSA (SAE/GAGI) pelas experiências trocadas durante esse processo.

À Juliana Jannuzzi e ao Edimar Perico, que me gentilmente me auxiliaram durante o processo.

Ao prof. Dr. Leonardo Borghi, por gentilmente ter aceitado me orientar e apoiar neste trabalho.

Ao meu coorientador e amigo Michael George Lowsby. Mais do que um orientador ou supervisor de estágio, um exemplo de geólogo e, acima disso, de ser humano. Me apadrinhou desde meu primeiro minuto dentro da Petrobras. Espero ser um geólogo tão bom quanto você e poder fazer por outros o que você fez por mim.

Por fim, agradeço ao geólogo Alexandre Pereira, meu querido tio. Você é minha inspiração. Com você, aprendi que dar broncas também é uma maneira de apoiar alguém. Obrigado por tudo.

RESUMO

CARDOSO, Davi de Souza. **Interpretação sísmica de falhas assistida por aprendizado de máquina no intervalo pré-sal no campo de Gato do Mato (Bacia de Santos)**. 2023. xx, 000 f. Trabalho Final de Curso (Geologia) – Departamento de Geologia, Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

O fluxo de interpretação de falhas é indispensável na geração de modelos estruturais, que são utilizados na definição de um modelo geológico. Entretanto, esta é uma tarefa predominantemente manual, de longa duração e altamente dependente da qualidade de dados sísmicos. No cenário atual de evolução tecnológica, as aplicações de Inteligência Artificial vêm despontando como ferramentas de grande impacto no fluxo de trabalho de interpretação sísmica, com o objetivo de reduzir o tempo e, de alguma maneira, melhorar a qualidade do modelo geológico. Assim, o objetivo deste trabalho é avaliar e comparar o uso de duas ferramentas de *machine learning* da aplicação Petrel para realizar o fluxo de interpretação assistida por máquina. Uma delas, baseada em um pré-treinamento mais generalizado realizado pela desenvolvedora do software, e outra baseada em interpretações manuais preliminares realizadas pelo intérprete. O estudo foi realizado no dado sísmico 3D do campo de Gato do Mato, da Bacia de Santos, a fim de mapear um conjunto de falhas para a definição do modelo estrutural no intervalo pré-sal da área a partir das duas metodologias. Foram realizadas três rodadas de aprendizado de máquina para a interpretação das falhas, uma na metodologia pré-treinada e duas na metodologia treinada pelo usuário. Nas rodadas treinadas pelo usuário, foram utilizadas como rótulos 7 *xlines* na primeira rodada e, na segunda rodada, houve o acréscimo de 4 *inlines*. Os resultados da metodologia pré-treinada não foram satisfatórios, pois apresentavam incoerências geológicas, como a detecção de falhas horizontais ou com geometrias irreais. Já os resultados da metodologia treinada pelo usuário foram consistentes, já que apresentaram coerência geológica, boa cobertura do cubo sísmico e permitiram interpretar menos seções sísmicas para se obter um cubo com todas as seções interpretadas. Além disso, observou-se a detecção de falhas não identificadas pelo intérprete em áreas de baixa amplitude e a melhoria na geometria das falhas. Somado a isso, as comparações permitiram concluir que o uso de rótulos em ambas as direções (*xlines* e *inlines*) contribui para interpretações mais eficazes. Neste sentido, a inteligência artificial foi eficaz no cumprimento da interpretação, configurando-se como uma metodologia com potencial para aprimorar os fluxos de interpretação sísmica. Ressalta-se também o papel crucial dos geocientistas no treinamento da máquina e na validação dos resultados obtidos.

Palavras-chave: Interpretação Sísmica, Aprendizado de Máquina, Bacia de Santos.

ABSTRACT

CARDOSO, Davi de Souza. **Seismic interpretation of faults and horizons assisted by machine learning in the pre-salt interval of the Gato do Mato field (Santos Basin)**. 2023. xx, 000 f. Trabalho Final de Curso (Geologia) – Departamento de Geologia, Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

The fault interpretation workflow is essential for generating structural models, which are used to define a geological model. However, this is a predominantly manual, time-consuming task that is highly dependent on the quality of seismic data. In the current technological evolution, Artificial Intelligence applications are emerging as highly impactful tools in the seismic interpretation workflow, aiming to reduce time and, in some way, improve the quality of the geological model. Therefore, the objective of this study is to evaluate and compare the use of two Machine Learning tools from the Petrel application to perform the machine-assisted interpretation workflow. One is based on more generalized pre-training performed by the software developer, and the other is based on preliminary manual interpretations performed by the interpreter. The study was conducted using 3D seismic data from the Gato do Mato field in the Santos Basin to map a set of faults for defining the structural model in the area's pre-salt interval using both methodologies. Three rounds of machine learning were performed to interpret the faults: one using the pre-trained methodology and two using the user-trained methodology. In the user-trained rounds, seven lines were used as carriers in the first round, and four lines were added in the second round. The pre-trained methodology was not overwhelming, as it presented geological inconsistencies, such as the detection of horizontal faults or faults with unrealistic geometries. The results of the user-trained methodology were consistent, achieving geological coherence, good seismic cube coverage, and allowing for the interpretation of fewer seismic bottles, resulting in a cube with all interpreted bottles. Furthermore, it was observed that faults missed by the interpretation were detected in low-amplitude areas and improved fault geometry. Furthermore, the comparisons concluded that the use of labels in both methods (xlines and inlines) contributes to more effective interpretations. In this sense, artificial intelligence was effective in completing the interpretation, establishing itself as a methodology with the potential to improve seismic interpretation workflows. The crucial role of geoscientists in training the machine and validating the results obtained is also noteworthy.

Keywords: Seismic Interpretation, Machine Learning, Santos Basin

LISTA DE FIGURAS

Figura 1 – Localização do prospecto Gato do Mato; modificado de ANP (2017).	18
Figura 2 – Mapa da localização da Bacia de Santos e da área do dado sísmico 3D R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-doMato.	18
Figura 3 – Carta estratigráfica de Moreira <i>et al.</i> (2007) com destaque em vermelho para a área de interesse: a seção Pré-sal da Bacia de Santos.	21
Figura 4 – Compartimentação tectônica para Província Mantiqueira (Setentrional, Central e Meridional) no contexto das faixas orogênicas neoproterozoicas, com destaque para a Faixa Ribeira que ocupa o segmento central desta província. Legenda: 1- Coberturas Fanerozoicas; 2- Província Tocantins/Mantiqueira; 3- Domínio Externo; 4- Domínio Interno; 5- Orógenos Apiaí e São Gabriel; 6- Coberturas Neoproterozoicas; 7- Crátons: CSF - Cráton do São Francisco; CLA - Cráton Luís Alves e CRP – Cráton Rio de La Plata. Fonte: Heilbron <i>et al.</i> , (2016).	22
Figura 5 – Estratigrafia com a correlação entre as proposições de evolução tectônica para a Bacia de Santos.	24
Figura 6 – Modelo geodinâmico esquemático da margem continental divergente. Adaptado de Mohriak (2004).	26
Figura 7 – Carta Esboço de mapas da evolução geodinâmica do Atlântico Sul mostrando estágios de evolução da margem passiva, desde a transição do rifte até a deriva e a formação de margens conjugadas divergentes entre Brasil e África Ocidental. Todas as seções não estão em escala. Retirado de Kukla <i>et al.</i> (2017).	27
Figura 8 – Bacia de Santos com seus principais elementos do seu arcabouço relacionados aos processos de estiramento crustal na região da Bacia de Santos. Retirado de ANP (2017). ...	33
Figura 9 – Subcampos da Inteligência Artificial (Junior, 2024).	35
Figura 10 – Convolução pela média; redução de uma matriz 4×4 (16 <i>pixels</i>) para uma matriz 2×2 (4 <i>pixels</i>) (Junior, 2024).	36

Figura 11 – Equação de convolução. Retirado de Deprez e Robinson (2022).	37
Figura 12 – Filtragem por convolução. Retirado de Deprez e Robinson (2022).	37
Figura 13 – Fluxo de trabalho para interpretação sísmica assistida por aprendizado de máquina.	39
Figura 14 – Dado sísmico R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-do-Mato [Realized] utilizado como <i>input</i> para a metodologia pré-treinada. Imagem da <i>xline</i> 1558.	41
Figura 15 – Cubo de probabilidade de falhas resultante da metodologia pré-treinada; <i>xline</i> 1558, <i>inline</i> 7950.	42
Figura 16 – Cubo de probabilidade de falhas resultante da metodologia pré-treinada (<i>depth slice</i> 7020 m).	43
Figura 17 – <i>Pointsets</i> resultantes da metodologia pré-treinada.	44
Figura 18 – Rótulos da primeira rodada; <i>xline</i> 1558.	47
Figura 19 – Rótulos da primeira rodada. Imagem em planta das linhas rotuladas sobrepostas à <i>depth slice</i> 7020.	48
Figura 20 – Rótulos da primeira rodada; representação das 7 <i>xlines</i> interpretadas.	49
Figura 21 – Cubo de probabilidade de falhas da primeira rodada; <i>xline</i> 1558.	50
Figura 22 – Comparação entre os rótulos e o cubo de probabilidade de falhas da primeira rodada. Imagens da <i>xline</i> 1558. [A]: Rótulos sobrepostos ao cubo de falhas. [B]: Cubo de falhas.	51
Figura 23 – Cubo de falhas da primeira rodada; <i>xline</i> : 1558, <i>inline</i> : 7660, <i>z</i> : 7020.	52
Figura 24 – Janela <i>Fault Extraction</i> mostrando os parâmetros do usuário utilizados para a extração dos objetos de pontos.	54
Figura 25 – representação da operação de mesclagem de <i>pointsets</i>	55

Figura 26 – <i>Pointsets</i> resultantes da primeira rodada de machine learning após o controle de qualidade.	56
Figura 27 – [A] <i>Pointsets</i> transformados em [B] <i>fault sticks</i> , resultantes da primeira rodada de machine learning após o controle de qualidade.	57
Figura 28 – Rótulos da segunda rodada; <i>inlines</i> 7470, 7570, 7660 e 7870.	58
Figura 29 – Rótulos da segunda rodada. Imagem em planta das 4 <i>inlines</i> interpretadas sobrepostas à <i>depth slice</i> 7020.	59
Figura 30 – Comparação entre os rótulos e o cubo de probabilidade de falhas da segunda rodada. Imagens da <i>xline</i> 1558. [A]: Rótulos sobrepostos ao cubo de falhas. [B]: Cubo de falhas.	60
Figura 31 – Cubo de falhas da segunda rodada; <i>xline</i> : 1558, <i>inline</i> : 7660, <i>z</i> : 7020.	61
Figura 32 – <i>Pointsets</i> resultantes da segunda rodada de <i>machine learning</i> após o controle de qualidade.	62
Figura 33 – [A] <i>Pointsets</i> transformados em [B] <i>fault sticks</i> , resultantes da segunda rodada de <i>machine learning</i> após o controle de qualidade.	64
Figura 34 – <i>Pointsets</i> resultantes da metodologia pré-treinada sobreposto à <i>xline</i> 1558.....	66
Figura 35 – [A] Estereograma plotado com as falhas da primeira rodada; observa-se um <i>trend</i> estrutural principal NNW/SSE - destacado em vermelho - e um secundário NW/SE - destacado em verde; [B] <i>pointsets</i> resultantes da primeira rodada sobrepostos à <i>depthslice</i> 7020.	67
Figura 36 – Resultados da metodologia treinada pelo usuário - primeira rodada; [A] <i>faultsticks</i> sobrepostos à <i>depthslice</i> 7020, [B] <i>faultsticks</i> vistos em 3D.	68
Figura 37 – [A] Estereograma plotado com as falhas da segunda rodada; observa-se um <i>trend</i> estrutural principal NNW/SSE - destacado em vermelho - e um secundário NW/SE -	

destacado em verde; [B] *pointsets* resultantes da segunda rodada sobrepostos à *depthslice* 7020. 69

Figura 38 – Resultados da metodologia treinada pelo usuário - segunda rodada; [A] *faultsticks* sobrepostos à *depthslice* 7020, [B] *faultsticks* vistos em 3D. 70

Figura 39 – Comparação entre os rótulos e o cubo de probabilidade de falhas da primeira rodada, imagem da *xline* 1558. Rótulos sobrepostos ao cubo de falhas. Destaque para a identificação de uma falha que não foi percebida pelo intérprete em uma região ruidosa. ...74

LISTA DE TABELAS

Tabela 1 – Parâmetros em <i>default</i> e alterados utilizados nas rodadas 1 e 2 de aprendizado de máquina.	61
----------------------------------------------------------------------------------------------------------------	----

SUMÁRIO

RESUMO.....	7
ABSTRACT.....	8
LISTA DE FIGURAS.....	9
LISTA DE TABELAS.....	13
SUMÁRIO.....	14
1. INTRODUÇÃO E OBJETIVO.....	16
2. ÁREA DE ESTUDO.....	17
2.1. Bacia de Santos.....	17
2.2. Geologia Regional.....	19
2.2.1. Embasamento Pré-Cambriano.....	22
2.2.2. Evolução Tectônica e Sedimentar da Bacia de Santos.....	23
2.2.2.1. Fase Rifte Inferior.....	28
2.2.2.2. Fase Rifte Superior.....	29
2.2.2.3. Fase SAG.....	30
2.2.2.4. Fase Drifte/Margem Passiva.....	31
2.2.3. Arcabouço Estrutural da Bacia de Santos.....	31
3. MATERIAIS E METODOLOGIA.....	34
3.1. Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo.....	34
3.1.1. Redes neurais convolucionais.....	36
3.2. Fluxo de Trabalho.....	38
3.3. Predição de Falhas: metodologia pré-treinada.....	40
3.4. Predição de Falhas: metodologia treinada pelo usuário.....	45
3.4.1. Primeira rodada.....	46

3.4.2. Segunda rodada.....	58
4. RESULTADOS.....	65
4.1. Resultados da metodologia pré treinada.....	65
4.2. Resultados da metodologia treinada pelo usuário - primeira rodada.....	67
4.3. Resultados da metodologia treinada pelo usuário - segunda rodada.....	69
5. DISCUSSÕES.....	71
5.1. Metodologia pré-treinada.....	71
5.2. Metodologia treinada pelo usuário.....	71
6. CONCLUSÕES.....	76
7. REFERÊNCIAS.....	78

1. INTRODUÇÃO E OBJETIVO

A interpretação sísmica aplicada à indústria de óleo e gás tornou-se uma tarefa indispensável em todas as suas possíveis frentes de atuação, desde a pesquisa exploratória mais embrionária de um possível play de óleo e gás até à sísmica de alta resolução para recuperação de campos maduros. O fluxo de interpretação de falhas é indispensável na geração de modelos estruturais, que são utilizados na definição de um modelo geológico. Tais modelos servem como base para uma futura avaliação econômica de uma determinada área/prospecto, e, posteriormente, no desenvolvimento de um campo. Entretanto, esta é uma tarefa predominantemente manual, de longa duração e altamente dependente da qualidade de dados sísmicos. Entretanto, novas tecnologias de aquisição e processamento estão ajudando a mitigar este problema.

Neste cenário de evolução tecnológica, a inteligência artificial tem se consolidado no mercado de óleo e gás em diversas frentes, inclusive nos fluxos exploratórios. Estas aplicações vêm despontando como ferramentas de grande impacto no fluxo de trabalho de interpretação sísmica, com o objetivo de reduzir o tempo e, de alguma maneira, melhorar a qualidade do modelo geológico. Guo *et al.* (2020) compilam diversos trabalhos que utilizam inteligência artificial para a interpretação automática de falhas. Além disso, alguns destes utilizam redes neurais convolucionais para diversas outras soluções, como inversão sísmica, classificação de sismofácies, identificação de corpos de sal (Vishal *et al.*, 2018; Zhao, 2018; Waldeland *et al.*, 2018).

Assim, o objetivo deste trabalho é avaliar e comparar o uso de duas ferramentas de *machine learning* da aplicação Petrel para realizar o fluxo de interpretação assistida por máquina. Uma delas, baseada em um pré-treinamento mais generalizado realizado pela desenvolvedora do software, e outra baseada em interpretações manuais preliminares realizadas pelo intérprete. O estudo foi realizado no dado sísmico do campo de Gato do Mato, da Bacia de Santos, a fim de mapear um conjunto de falhas e para a definição do modelo

estrutural no intervalo pré-sal da área. Para isso, foi utilizada a sísmica 3D R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-doMato, solicitada à ANP através do peticionamento nº 48610.215775/2025-92 - Recibo Eletrônico de Protocolo SEI nº 5051799 - e fornecida pela mesma.

2. ÁREA DE ESTUDO

2.1. Bacia de Santos

A Bacia de Santos localiza-se no sudeste brasileiro e faz parte do conjunto de bacias *offshore* da margem leste. Sua exploração iniciou-se nos anos 70 do século passado, porém sua primeira descoberta aconteceu na década seguinte, em arenitos turbidíticos de talude da Formação Itajaí-Açu, no campo de Merluza (ANP, 2017). Apesar de sua pequena expressão produtora até os anos 2000, as descobertas do Pré-sal elevaram a relevância econômica desta bacia a um novo patamar. Atualmente, ela é responsável por 74,08% da produção nacional de petróleo, bem como por 75,34% da produção nacional de gás natural de acordo com a ANP (2023).

A evolução do conhecimento geológico desta bacia permitiu a identificação de diferentes *plays*. Observa-se *plays* exploratórios como os carbonatos Barremiano e Aptiano das formações Itapema e Barra Velha, os carbonatos Albianos da Formação Guarujá, os arenitos turbidíticos da Formação Itajaí-Açu (Membro Ilhabela) e os arenitos turbidíticos da Formação Marambaia (Membro Maresias) (Silva, 2021).

Dentro dessa diversidade de *plays*, encontra-se o campo de Gato do Mato (Figuras 1 e 2). O prospecto se encontra no bloco BMC-S-54 e, de acordo com ANP (2017), apresenta uma estrutura Norte-Sul com fechamento estrutural bem definido. A estrutura contém óleo de leve a muito leve e gás em reservatórios de carbonato do Aptiano, com características microbiais, selada por uma espessa camada de evaporitos.

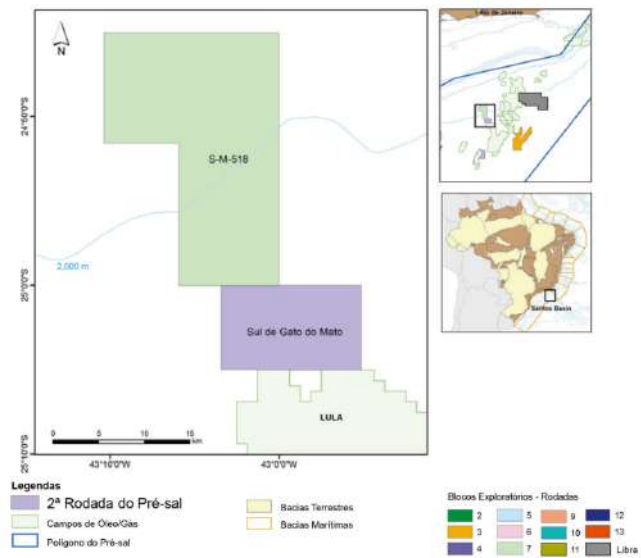


Figura 1: Localização do prospecto Gato do Mato; modificado de ANP (2017).

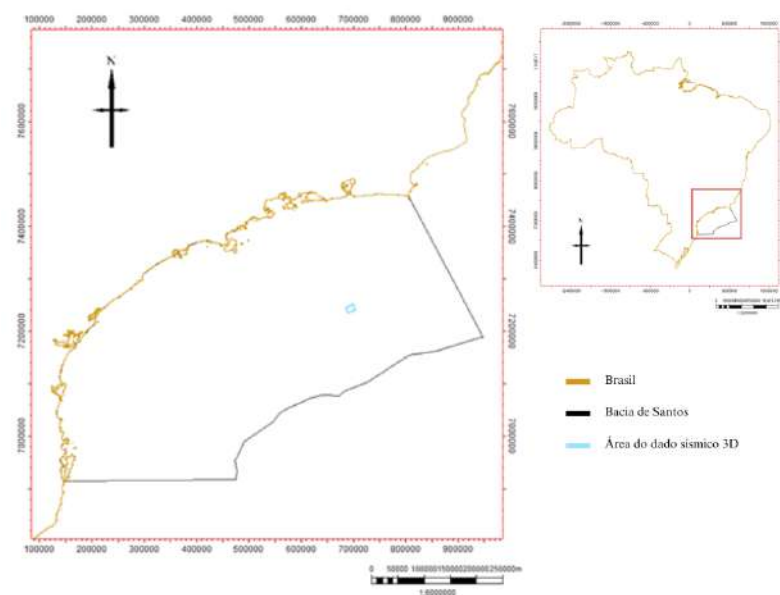


Figura 2: Mapa da localização da Bacia de Santos e da área do dado sísmico 3D
R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-doMato.

2.2. Geologia Regional

A Bacia de Santos localiza-se na margem sudeste do Brasil, entre os paralelos 23°S e 28°S, abrangendo uma área aproximada de 275.000 km² até a isóbata de 2000 metros. Seus limites geográficos são definidos, ao norte, pelo Alto de Cabo Frio, que a separa da Bacia de Campos, e, ao sul, pela Plataforma de Florianópolis, que marca a transição para a Bacia de Pelotas (Pereira & Feijó, 1994). A gênese da Bacia de Santos remonta ao Jurássico Superior, período no qual o supercontinente Gondwana iniciou seu processo de fragmentação por meio do rifteamento continental, culminando na formação de uma bacia do tipo margem passiva. Esse processo teve início no setor meridional da margem atlântica, entre as atuais regiões da Argentina e da África do Sul, propagando-se posteriormente, durante o Cretáceo Inferior, em direção às bacias de Pelotas, Santos e Campos (Mohriak *et al.*, 1995).

O embasamento cristalino da Bacia de Santos é constituído predominantemente por rochas graníticas e gnáissicas de idade pré-cambriana, pertencentes ao Complexo Costeiro, bem como por unidades metassedimentares relacionadas à Faixa Ribeira. O embasamento econômico da bacia — definido como o conjunto de rochas abaixo do qual as chances de ocorrência de recursos minerais com potencial econômico são consideradas mínimas — é representado pelos basaltos da Província Magmática Paraná-Etendeka. Essas rochas correspondem à Formação Camboriú e recobrem discordantemente o embasamento pré-cambriano (Moreira *et al.*, 2007).

Moreira *et al.* (2007) descrevem o preenchimento sedimentar da Bacia de Santos em sua carta estratigráfica (Figura 3), que tem início com os depósitos da Formação Piçarras, composta por conglomerados, arenitos, siltitos e folhelhos de origem continental, depositados durante o Barremiano. Sobreposta a esta unidade, está a Formação Itapema, caracterizada por arenitos, folhelhos escuros e coquinas, depositados no contexto das primeiras incursões marinhas na bacia, ocorridas entre o Neobarremiano e o Eoaptiano.

Em sequência, Moreira *et al.* (2007) descrevem a ocorrência dos depósitos carbonáticos de idade Aptiana da Formação Barra Velha, desenvolvidos em ambientes lacustres continentais alcalinos rasos, os quais representam os principais reservatórios da seção do Pré-Sal na Bacia de Santos. Sobre esta formação, encontra-se a seção evaporítica da Formação Ariri, de idade Neoaptiana, fortemente estratificada e composta predominantemente por halita, anidrita e sais complexos, tais como taquidrita, carnalita e, localmente, silvinita (Moreira et al., 2007).




Figura 3: Carta estratigráfica de Moreira *et al.* (2007) com destaque em vermelho para a área de interesse: a seção Pré-sal da Bacia de Santos.

2.2.1. Embasamento Pré-Cambriano

Moreira *et al.* (2007) descrevem o embasamento cristalino da Bacia de Santos como granitos e gnaisses de idade pré-cambriana pertencentes à Faixa Ribeira que, por sua vez, pertencente à Província Mantiqueira. Segundo Heilbron *et al.* (2004), a Província Mantiqueira (Figura 4) engloba os orógenos Araçuaí, Ribeira, Brasília meridional, Dom Feliciano e São Gabriel, que se distribuem desde o sul do Estado da Bahia até o Estado do Rio Grande do Sul. Levando em consideração o fato de que o embasamento econômico da bacia de Santos é a faixa Ribeira, será detalhada apenas a geologia desta.

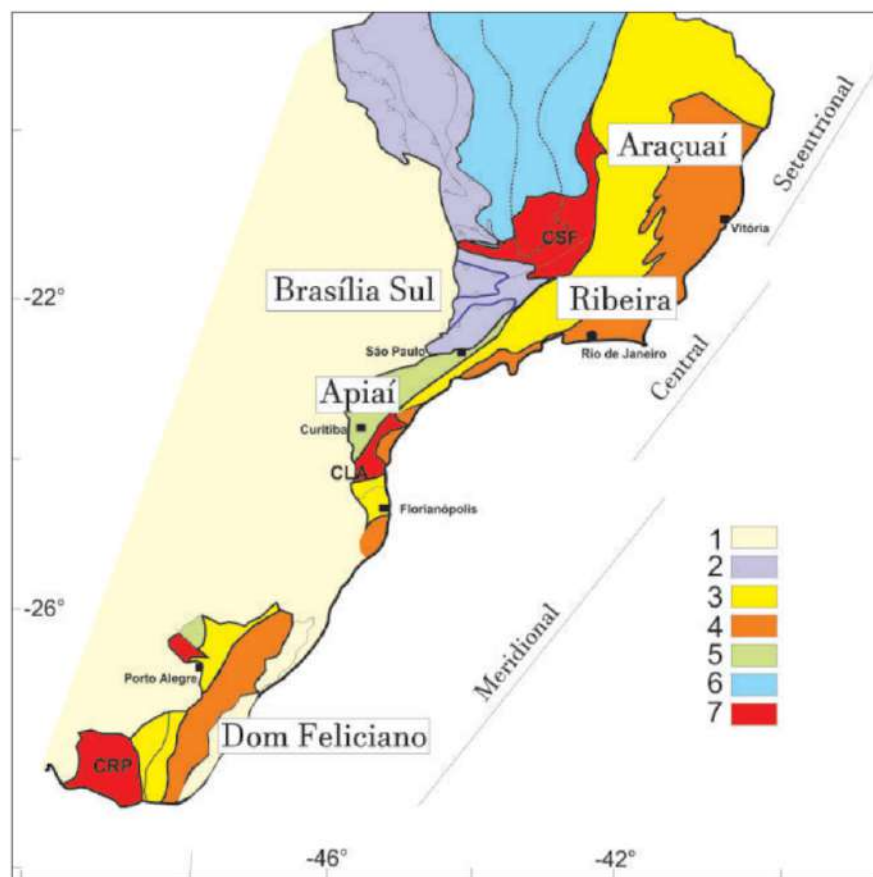


Figura 4: Compartimentação tectônica para Província Mantiqueira (Setentrional, Central e Meridional) no contexto das faixas orogênicas neoproterozoicas, com destaque para a Faixa Ribeira que ocupa o segmento

central desta província. Legenda: 1- Coberturas Fanerozoicas; 2- Província Tocantins/Mantiqueira; 3- Domínio Externo; 4- Domínio Interno; 5- Orógenos Apiaí e São Gabriel; 6- Coberturas Neoproterozoicas; 7- Crátons: CSF - Cráton do São Francisco; CLA - Cráton Luís Alves e CRP – Cráton Rio de La Plata. Retirado de CPRM (2016).

De Acordo com CPRM (2016), a Faixa Ribeira constitui um sistema orogênico de direção NE, que se entende por 1400 km ao longo da costa S-SE do Brasil, resultado da colisão entre o paleocontinente (cráton) São Francisco-Congo com a parte ocidental do Cráton da Angola. Essa colisão integra os processos da Orogenia Brasileira-Panafricana, que ocorreu durante o Neoproterozoico-Cambriano.

O Orógeno Ribeira apresenta trend estrutural NE-SW, que é resultado da interação entre o Cráton do São Francisco e outra(s) placas e/ou microplaca(s) e/ou arco de ilhas situado(s) a sudeste deste cráton, bem como com a porção sudoeste do Cráton do Congo. Esta segunda etapa de colisão continental (ca. 580 Ma) resultou no empilhamento de terrenos de leste para oeste-noroeste (Heilbron *et al.*, 2004).

2.2.2. Evolução Tectônica e Sedimentar da Bacia de Santos

Existem diversos trabalhos que discutem e apresentam propostas para a evolução tectônica da bacia de Santos, desde o início da fase de rifteamento de seu embasamento cristalino até as fases de deposição das bacias de margem passiva. Por esta razão, se fez necessária uma revisão bibliográfica para comparação de proposições sobre a evolução da bacia, a fim de definir o referencial adotado para este trabalho.

Moreira *et al.* (2007) desenvolve acerca do arcabouço crono-litoestratigráfico da bacia de Santos com ênfase na individualização em sequências deposicionais, descrevendo assim o embasamento cristalino e, em seguida, as supersequências Rife, Pós-Rife e Drifte. Já Chang *et al* (2008) apresenta uma divisão semelhante à apresentada por Karner & Driscoll (1999)

para as bacias marginais do oeste africano, propondo três fases rifte: Sin-rifte I, Sin-rifte II e Sin-rifte III ou *sag*. As correspondências entre as fases destas propostas se encontram na figura xxx.

É necessário ressaltar que o trabalho de Chang et al. (2008) não considera o trabalho de Moreira et al. (2007), mas baseia-se na carta estratigráfica proposta por Pereira & Feijó (1994). Além disso, as proposições de classificações tectônicas feitas pelo trabalho de Chang et al (2008) são relativas às fases anteriores à fase drift ou margem passiva e, por isso, esta não é discutida. Desta maneira, .

Tempo (Ma)	Período	Era	Discordâncias	Formações	Evolução Tectônica			
					Moreira <i>et al.</i> (2007)	Chang <i>et al.</i> (2008)	Wright & Barnett (2015)	Adotada para este trabalho
110	Cretáceo	Albiano		Guarujá	Drifte	Margem Passiva		Drifte / Margem Passiva
		Aptiano	Base do Sal	Ariet	Pós Rift	Sin-rifte III	SAG	SAG
120			Intra-Alagoas	Barra Velha Superior			Rifte	Rifte Superior
		Barreniano	Pré-Alagoas	Itapema	Rifte	Sin-rifte II		Rifte Inferior
130		Hauteriviano	Embasamento Econômico	Piçarra		Sin-rifte I		
				Camboriú				

Figura 5: Estratigrafia com a correlação entre as proposições de evolução tectônica para a Bacia de Santos.

Mohriak (2004) propõe um esquema em seção que ilustra a evolução da margem leste brasileira em cinco fases, como mostra a figura 6. Em (a) a primeira fase representa o início dos processos extensionais da separação América do Sul – África; (b) o segundo estágio marca a fase sin-rifte em seu estágio inicial, com aumento no estiramento litosférico e extrusão de lavas basálticas. (c) a terceira fase marca o início da fase sag, onde predominam a quiescência tectônica e a subsidência termal posterior ao final da fase rifte. É marcada pela discordância Intra-Alagoas, que representa o momento de ruptura continental do Gondwana;

(d) o quarto estágio representa a fase drifte, momento em que se inicia a intrusão da crosta oceânica. Por fim, a quinta e última fase (e) é o estágio de margem passiva, que é marcado pela acumulação de sedimentos siliciclásticos marinhos de águas profundas.

EVOLUÇÃO TECTONO-SEDIMENTAR

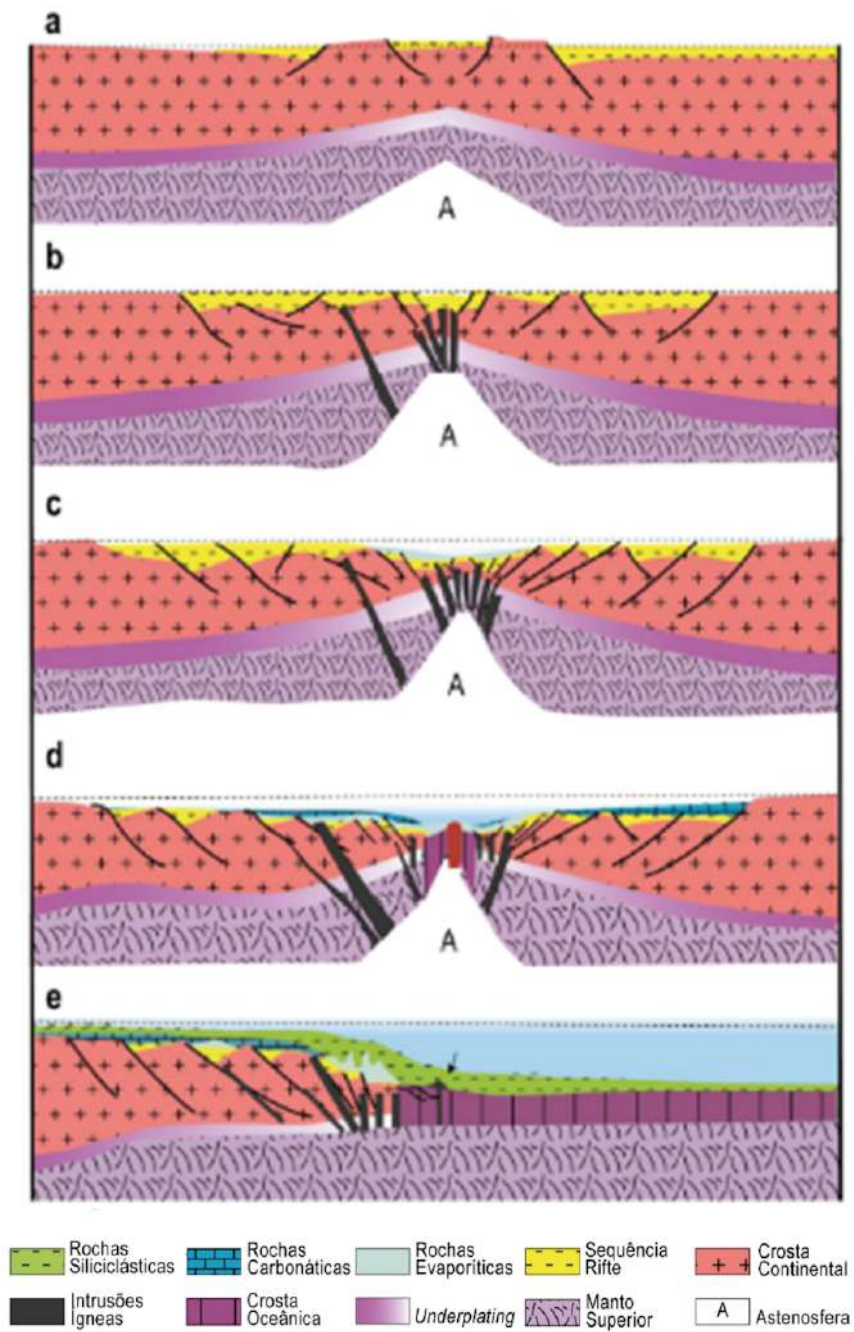


Figura 6: Modelo geodinâmico esquemático da margem continental divergente. Adaptado de Mohriak (2004).

Kukla et al. (2017) propuseram um modelo esquemático em planta para representar a evolução da margem passiva do sudeste brasileiro, conforme ilustrado na figura 7. Nesse modelo, os autores enfatizam o papel do núcleo de propagação do rifte, destacando o controle exercido por essa estrutura sobre as distintas fases da evolução tectono-sedimentar da margem. Particular atenção é dada às implicações da migração desse núcleo na deposição evaporítica, especialmente nas bacias de Campos e Santos.

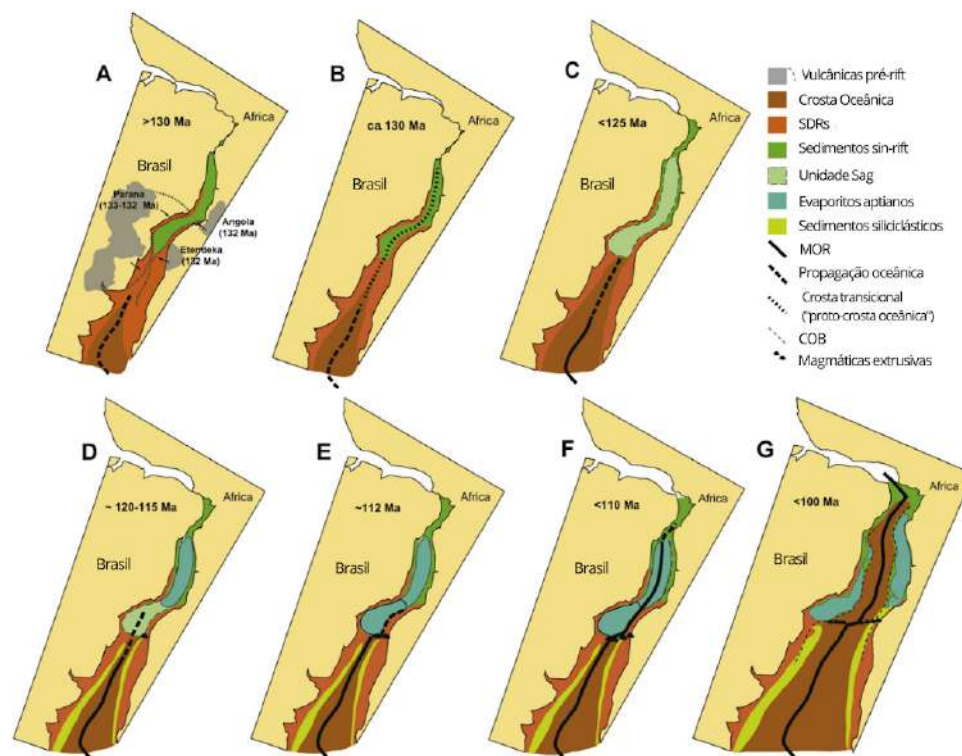


Figura 7: Carta Esboço de mapas da evolução geodinâmica do Atlântico Sul mostrando estágios de evolução da margem passiva, desde a transição do rifte até a deriva e a formação de margens conjugadas divergentes entre Brasil e África Ocidental. Todas as seções não estão em escala. Retirado de Kukla *et al.* (2017).

O modelo de Kukla *et al.* (2017) - figura 7 – descreve as fases: (A) rifteamento e preenchimento do graben sin-rift no segmento central; (B) propagação do espalhamento a partir do segmento sul e alocação de rochas magmáticas intrusivas no rifte central bacias do segmento central; (C) deposição de sedimentos da fase sag no topo da crosta continental rifteada (bacias proximais) e de magmáticas intrusivas (bacias distais); (D) avanço do propagador magmático na Bacia Central de Santos; aumento da deposição siliciclástica no segmento sul; deposição da antiga província salina do Aptiano na parte norte do segmento central; (E) cessação do propagador na Bacia de Santos e migração do núcleo de propagação em direção à margem africana; deposição de sal nas Bacias de Santos/Campos; (F) avanço do núcleo de propagação por toda a província salina do Aptiano; (G) configuração final pós-separação de ambas as margens continentais.

2.2.2.1. Fase Rifte Inferior

A fase Rifte Inferior corresponde à fase Rifte de Moreira *et al.* (2007) e é equivalente às fases sin-rifte I e sin-rifte II descritas por Chang *et al.* (2008) (figura 5). Ela se estende do Hauteriviano até o limite Barremiano-Aptiano e, nela, destacam-se as formações Piçarras e Itapema. Segundo Moreira *et al.* (2007), a primeira é definida por leques aluviais de conglomerados, arenitos polimíticos e folhelhos de composição talco-estevensítica nas porções lacustres, e engloba os sedimentos depositados desde o estágio inicial até o estágio de máxima atividade da formação dos meio-grábens. Já a segunda, é definida pelas sequências das coquinas, intercalações de calcirruditos e folhelhos escuros, e engloba os sedimentos depositados no estágio final da formação dos meio-grábens, quando as falhas principais diminuem a atividade até cessar quase completamente. O limite superior da Fm. Piçarras com a parte inferior da Fm. Barra Velha é dado pela discordância pré-Alagoas (Moreira *et al.*; 2007).

O rifte Sul-Atlântico propagou-se de sul para norte, controlado pela distribuição de tensões regionais que condicionou a atenuação litosférica em ampla faixa de deformação, com estruturas de direção aproximada N-NNE na porção sul da Bacia de Santos. Durante esta fase, ocorreu o confinamento dos esforços na porção da crosta que sofreu afinamento, provocando falhas crustais. Em seguida, a deformação foi concentrada nas porções crustais superiores (estiramento supracrustal), com a formação de sistemas de falhas com ângulo de caimento menor, porém distribuídas por uma área mais ampla (Chang *et al.*, 2008).

2.2.2.2. Fase Rifte Superior

A fase Rifte Superior diz respeito ao período de deposição da parte inferior da formação Barra Velha e está correlacionada com as partes inferiores das fases Pós-Rifte de Moreira *et al.* (2007) e sin-rifte III de Chang *et al.* (2008), correspondendo ao andar local Alagoas inferior. A formação Barra Velha é caracterizada por calcários estromatolíticos microbiais, cuja produção e acumulação em lagos conectados com um oceano próximo teriam sido induzidas por organismos microbianos, intercalados a folhelhos e laminitos microbiais. Estes calcários estão localmente dolomitizados e foram depositados em um ambiente transicional (Moreira *et al.*, 2007; Riccomini *et al.*, 2012).

Segundo Chang *et al.* (2008), esta fase caracterizou-se por sistemas de falhas de pequena magnitude, concentradas na porção superior da seção rifte, seguidos do desenvolvimento de uma ampla depressão tipo *sag*, lateralmente contínua. Desta maneira, Wright & Barnett (2015) descrevem uma discordância que divide os andares Alagoas Inferior e Alagoas Superior, ou seja, divide internamente a formação Barra Velha e a separa em Microbialito tipo rifte (inferior) e Microbialito tipo *sag* (superior). Esta é denominada discordância Intra-Alagoas, ou discordância pré-Aptiano Superior.

A discordância Intra-Alagoas teria sido ocasionada pelo deslocamento da deformação crustal para as porções axiais do sistema rifte. Este deslocamento resultou na exposição subaérea de grande parte das porções proximais das bacias, que foram recobertas pelos sedimentos do andar Aptiano Superior ou mais novos, segundo Dias (2005).

A fase Rifte Superior corresponde ao andar Aptiano Inferior (porção terminal do Andar Jiquiá e Andar Alagoas Inferior), que é caracterizado por uma sedimentação predominantemente continental, em um ambiente transicional, entre continental e marinho raso, com incursões marinhas que ocorreram durante o final da fase rifte inferior. Com relação à litologia, houve a deposição de calcários microbiais, estromatólitos e laminitos nas porções proximais e folhelhos nas porções distais (Dias, 2005 ; Moreira *et al.*, 2007).

2.2.2.3. Fase SAG

A fase *sag* da bacia de Santos corresponde ao andar Aptiano Superior (ou Alagoas Superior) e às partes inferiores das fases Pós-Rifte de Moreira *et al.* (2007) e sin-rifte III de Chang *et al.* (2008). Ela se estende da discordância Intra-Alagoas até o topo da formação Ariri, logo abaixo do pós-sal. Dias (2005) descreve o andar Aptiano Superior como caracterizado por uma sedimentação marinha que ocorreu em ambiente de quiescência tectônica com falhamentos localizados, num contexto de fase *sag*. Neste período, a sedimentação continental foi predominante apenas nas porções proximais das bacias marginais; nas porções mais distais os sedimentos foram depositados num ambiente marinho raso de um mar epicontinental.

A partir deste contexto, ocorre expressiva sedimentação evaporítica, que resultou na deposição da formação Ariri, condicionada pela presença de altos vulcânicos (Dorsal de São Paulo) que causaram restrição à circulação de águas do oceano providas de sul (Chang *et al.*, 2008). A formação Ariri é caracterizada por evaporitos compostos majoritariamente por

halita e anidrita, ainda com presença de sais solúveis, tais como, taquidrita, carnalita e silvinita (Moreira *et al.*, 2007).

2.2.2.4. Fase Drifte/Margem Passiva

Por fim, a supersequência Drifte, descrita por Moreira *et al.* (2007), vai do Albiano inferior até o Pleistoceno. Nela, destacam-se o membro Tombo, da formação Itanhaém, e o membro Maresias, da formação Marambaia. O primeiro é do Albiano superior e, o segundo, do Eoceno ao Oligoceno. Ambos são caracterizados por arenitos cinza-esbranquiçados, relacionados a fluxos gravitacionais turbidíticos em ambiente marinho de talude e bacia, e ocorrem de forma canalizada ou sob a forma de leques.

A megassequência marinha inicia-se por sedimentação predominantemente carbonática, com o período Albiano dominado por plataformas de águas rasas. Ao fim desse intervalo, adentrando no Cenomaniano e Turoniano, ocorre um aumento de paleobatimetria, terminando a deposição carbonática e resultando na acumulação de sedimentos marinhos.

2.2.3. Arcabouço Estrutural da Bacia de Santos

A Bacia de Santos tem sua origem ligada aos processos tectônicos que causaram a ruptura e separação do supercontinente Gondwana, durante o Juro-Cretáceo. As características estruturais da bacia sugerem tratar-se de um prolongamento em direção leste das rochas granito-gnáissicas da Faixa Ribeira (setor continental), as quais se encontram intensamente afetadas por falhas transcorrentes pré-cambrianas, predominantemente orientadas na direção NE-SW (Pereira & Macedo, 1990).

Os processos de rifteamento que originaram a Bacia de Santos nuclearam-se ao longo de estruturas preexistentes do embasamento, que governaram a arquitetura das principais feições do sistema rifte, com as principais falhas normais herdando a direção NE-SW. Esta direção predominante do embasamento é oblíqua à direção de abertura do rifte (E-W), resultando em regime tectônico geral de transtensão sinistral durante a abertura da bacia (Carvalho; Mello; Junior, 2024). Extensões diferenciais da crosta continental durante a fase rifte favoreceram a implantação de três importantes zonas ou faixas de transferência, a saber: Zona de Transferência do Rio de Janeiro, de Curitiba e de Florianópolis (Pereira & Macedo, 1990).

A Bacia de Santos é limitada ao norte pelo Alto de Cabo Frio, como exemplificado na figura 8, estrutura que exerce controle significativo sobre os depocentros sin-rifte das Bacias de Campos e Santos. Além disso, o Alto de Cabo Frio está associado a eventos tectono-magmáticos pós-rifte, ocorridos entre o Santoniano e o Eoceno. As sucessões sedimentares da seção pós-sal situadas próximas à Falha de Cabo Frio são controladas por esta expressiva falha antitética, cuja atuação resultou na formação do gap albiano. Esta feição, de grande relevância geológica, apresenta orientação preferencial NE-SW e se estende em direção ao setor central da bacia (Mohriak e Paula, 2005).

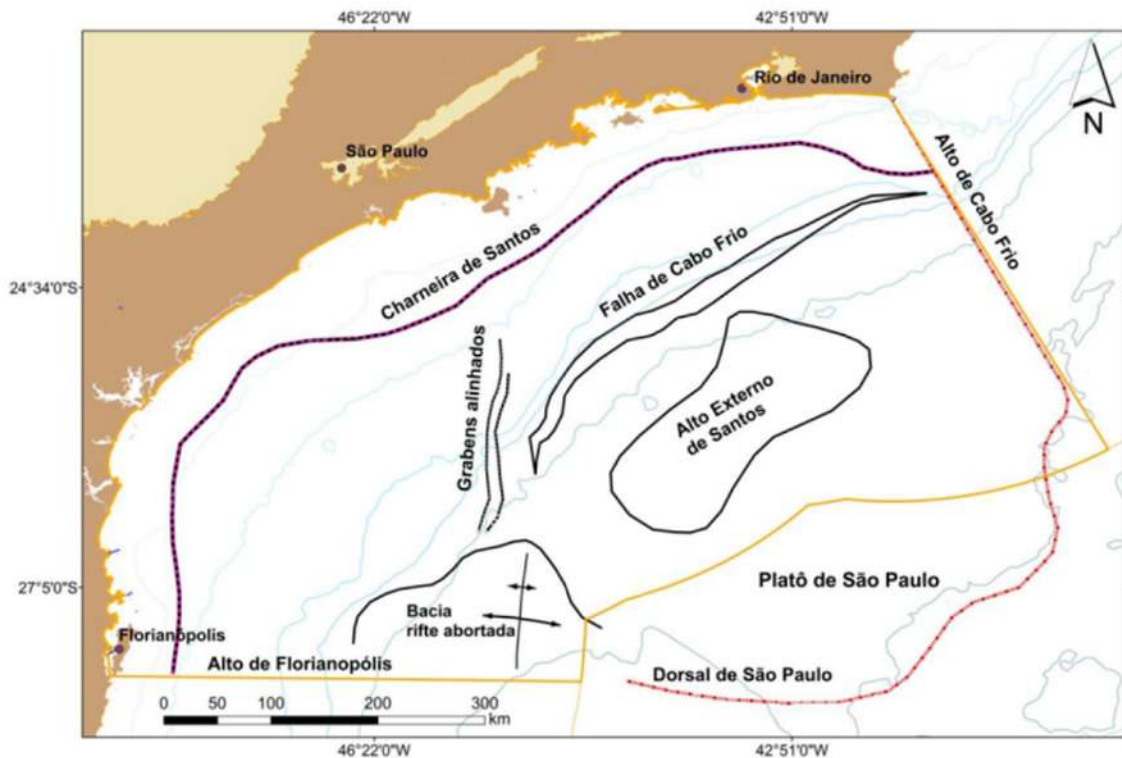


Figura 8: Bacia de Santos com seus principais elementos do seu arcabouço relacionados aos processos de estiramento crustal na região da Bacia de Santos. Retirado de ANP (2017).

O Alto de Florianópolis apresenta direção aproximada WNW-ESSE e é a estrutura que limita as bacias de Santos e Pelotas. A Dorsal de São Paulo – ou Lineamento Florianópolis - aparentemente coincide com a extensão mais ao sul do Platô de São Paulo e parece mostrar seu prolongamento continental associado ao Alto de Florianópolis (Mohriak et al., 1995; Borges e Gambôa, 2015)

O Platô de São Paulo constitui uma estrutura que se caracteriza por uma feição marginal proeminente no fundo marinho, que se estende desde a Bacia de Santos até a Bacia do Espírito Santo e apresenta em sua maior parte um substrato de crosta continental (Borges e Gambôa, 2015; Mohriak, 2004). São três os principais fatores determinantes na morfologia

atual do platô: grande área de crosta estirada por baixo do platô, ciclos de atividade magmática e a presença de espessa camada de evaporitos (Borges e Gambôa, 2015) .

3. MATERIAIS E METODOLOGIA

Os materiais utilizados para o desenvolvimento deste trabalho foram o dado sísmico R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-do-Mato e o software Petrel, da empresa SLB, na versão 2024.1.

3.1. Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo

Belyadi e Haghighat (2021) definem inteligência artificial, tradução livre do termo em inglês *artificial intelligence* (AI) como o uso da inteligência de máquina ou computador em vez da inteligência humana ou animal. É um ramo da ciência da computação que estuda a simulação de processos de inteligência humana, como aprendizagem, raciocínio, resolução de problemas e autocorreção por computadores. Serão abordados dois tópicos que estão englobados dentro de inteligência artificial: aprendizado de máquina e aprendizado profundo. Estes assuntos se relacionam da maneira descrita na figura 9.

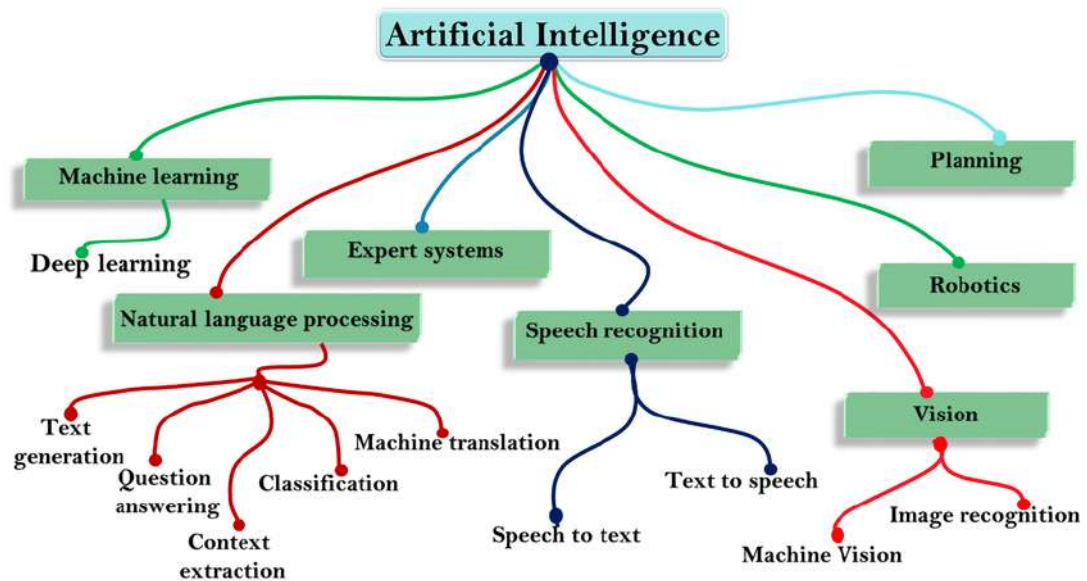


Figura 9: Subcampos da Inteligência Artificial (Junior, 2024).

Aprendizado de máquina, do inglês *machine learning* (ML) é um subtópico de AI e é definido por Belyadi e Haghighat (2021) como o conjunto de métodos que utilizam vários algoritmos para ensinar computadores a encontrar padrões em dados a serem usados para previsões futuras ou como uma verificação de qualidade para otimização de desempenho.

Aprendizado profundo ou *deep learning* é definido como um tipo de aprendizado de máquina em que diferentes formas de redes neurais complexas são usadas no aprendizado do algoritmo para descobrir padrões em grandes conjuntos de dados (Belyadi e Haghighat, 2021). Os principais blocos para a construção de algoritmos de aprendizado profundo são as redes neurais. As redes neurais são inspiradas em processos biológicos, desenvolvidas por McCulloch e Pitts (1943) e são modeladas matematicamente com base na funcionalidade das redes neurais biológicas. Belyadi e Haghighat (2021) defendem que as redes neurais geralmente consistem em uma série de "neurônios" em uma estrutura de camadas

sequenciais, onde cada variável de entrada e saída pode ser atribuída a um nó, semelhante a um neurônio biológico.

3.1.1. Redes neurais convolucionais

Dentre os diversos tipos de redes neurais, destaca-se as redes neurais convolucionais – *convolutional neural networks* (CNNs) – que são arquiteturas de redes neurais especializadas. Elas incorporam conhecimento sobre as invariâncias de formas bidimensionais (2D) usando padrões de conexão locais e impondo restrições aos pesos (LeCun *et al.*, 1998) e são importantes em aplicações de processamento de imagens e visão computacional.

Segundo Belyadi e Haghighat (2021), a operação de convolução, parte principal da CNN, aplica filtros específicos - ou funções de kernel (“núcleo” de convolução) - a uma região selecionada da imagem para detectar características locais. A depender do kernel utilizado, é possível manipular a imagem ou detectar padrões específicos como linhas, bordas e curvas. Em outras palavras, por meio da convolução, é possível focar em uma característica específica da imagem por vez, aplicando filtros específicos. Assim, a rede “aprende” os filtros que precisariam ser implementados manualmente em um algoritmo tradicional. Um exemplo seria a convolução pela média, demonstrada na figura 10:




Figura 10: Convolução pela média; redução de uma matriz 4x4 (16 *pixels*) para uma matriz 2x2 (4 *pixels*) (Junior, 2024).

Deprez e Robinson (2022) descrevem a filtragem por convolução (figura 11), onde o filtro é aplicado a todos os locais da imagem e a intensidade de saída é calculada por média ponderada usando os pesos do filtro. Para isso, denota-se os pixels da imagem por x_{ij} e elementos de um filtro w_{kl} . No nosso caso, os valores de k e l são -1 , 0 e 1 , pois temos núcleos de convolução 3×3 (figura 12). A convolução pode ser escrita matematicamente como a fórmula da imagem 11, onde s significa que o tamanho do núcleo é $2s + 1 \times 2s + 1$.

$$(w \star x)_{ij} = \sum_{k=-s}^s \sum_{l=-s}^s w_{kl} x_{i+k, j+l}$$

Figura 11: Equação de convolução. Retirado de Deprez e Robinson (2024).




Figura 12: Filtragem por convolução. Retirado de Deprez e Robinson (2024).

A partir dessa equação, podemos ver que, para cada localização (i,j) , sobrepomos o núcleo de convolução w sobre a imagem x e realizamos a média ponderada das intensidades dos pixels usando os pesos no núcleo. Na figura 12, observamos a representação de uma filtragem por convolução. O quadrado vermelho na imagem de entrada mostra a posição do filtro sobre o local (3,5). O valor resultante no mesmo local na imagem de saída também é mostrado por um quadrado vermelho.

Dentro deste contexto, uma abordagem de rede neural convolucional (CNN) pode ser usada para identificar a localização de falhas em dados sísmicos com base em um conjunto de treinamento sintético ou em seleções manuais ou automatizadas de falhas em dados sísmicos, como descrito por Lorentzen *et al.* (2022).

3.2. Fluxo de Trabalho

A partir dos dados fornecidos (sísmica), foi realizado um fluxo de trabalho, que abrange desde a criação de um projeto Petrel até a construção do modelo estrutural. Foram gerados dois cenários para o mapeamento de falhas. São eles: predição de falhas por aprendizado de máquina na metodologia pré-treinada e predição de falhas por aprendizado de máquina na metodologia treinada por usuário. Desta maneira, os procedimentos do fluxo de trabalho estão registrados na figura 13.

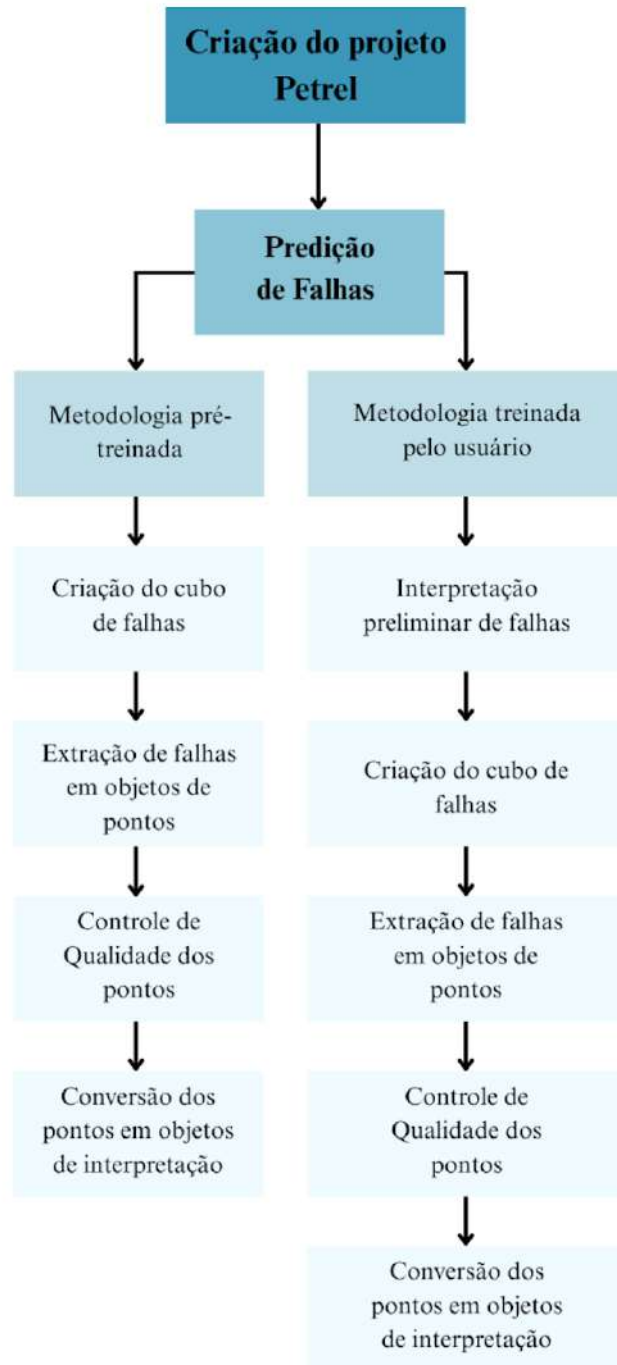


Figura 13: Fluxo de trabalho para interpretação sísmica assistida por aprendizado de máquina.

O dado sísmico original em formato ZGY (figura 14) possui 3,2361Gb, enquanto o dado sísmico cortado no intervalo de interesse - de 5000m a 9000m - possui 0,3596 Gb; ambos com 641 *inlines* e 441 *xlines*. O dado está localizado entre as latitudes 24°59'2"28.1500"S e 24°50'33.7295"S e as longitudes 43°10'17.8344" W e 42°58'53.7650"W. Sua profundidade máxima é de 9001,5 m.

3.3. Predição de Falhas: metodologia pré-treinada

A primeira metodologia utilizada foi a 3D *Pre-trained fault prediction*. Esta ferramenta do Petrel utiliza o algoritmo de CNN de *Deep Learning* e rótulos de bacias sedimentares ao longo do mundo para gerar um modelo de predição de falhas sem a necessidade de o usuário inserir rótulos (interpretações preliminares). Dessa maneira, apenas o cubo de amplitude original foi utilizado como *input* na interpretação das falhas.

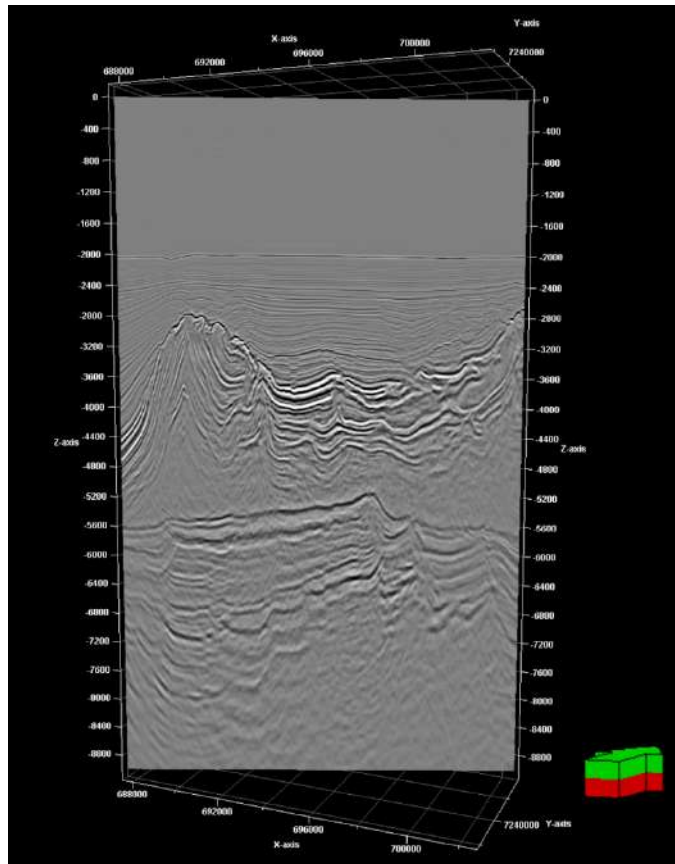


Figura 14: Dado sísmico R0276_BS500_MERGE_PSDM_Correct_Tol_1_FS_subset-Gato-do-Mato [Realized] utilizado como *input* para a metodologia pré-treinada. Imagem da *xline* 1558.

Após o carregamento de seleção do cubo sísmico, roda-se o módulo de aprendizado de máquina e obtém-se como produto um cubo de falhas, no qual os locais que apresentam falhas tem o valor igual a 1 e o restante do cubo tem valores iguais a 0. Os cubos de falhas representam a probabilidade de existir uma falha no local indicado ao extrair-se os objetos de pontos (*point sets*).

➤ Criação do cubo de falhas

O cubo de falhas da metodologia pré-treinada está representado nas figuras 15 e 16.




Figura 15: Cubo de probabilidade de falhas resultante da metodologia pré-treinada; *xline* 1558, *inline* 7950.




Figura 16: Cubo de probabilidade de falhas resultante da metodologia pré-treinada (*depth slice* 7020 m).

➤ Extração de falhas em objetos de pontos

O método de predição de falhas pré-treinado resultou em um cubo com inconsistências geológicas significativas, as quais já eram antecipadas, considerando-se a particularidade geológica da área de estudo e a baixa amplitude do dado sísmico disponível. As etapas subsequentes previstas no fluxo de trabalho compreenderiam o controle de qualidade dos *pointsets* e, posteriormente, a conversão dos mesmos em objetos de interpretação. No entanto, em virtude dos resultados insatisfatórios obtidos no cubo de falhas e nos objetos de pontos, optou-se por não dar continuidade ao fluxo, ou seja, não foram

gerados *faultsticks*. As limitações e incoerências observadas nesta metodologia serão discutidas em maior detalhe no tópico **Discussões**. Os *pointsets* resultantes da metodologia pré-treinada estão representados na figura 17.




Figura 17: *Pointsets* resultantes da metodologia pré-treinada.

3.4. Predição de Falhas: metodologia treinada pelo usuário

Na metodologia treinada pelo usuário, a aplicação (Petrel) também utiliza o algoritmo de CNN de *Deep Learning*. A diferença para o anterior é que falhas interpretadas manualmente (rótulos) são utilizadas como dado de treinamento do algoritmo para a geração das falhas. Vale ressaltar que a rotulagem deve ser consistente e representar o que é geologicamente plausível, honrando o que é observado no dado sísmico. Ou seja, a qualidade do modelo está diretamente atrelada à qualidade da rotulagem. A rotulagem consiste em um único objeto de interpretação. A partir da criação deste objeto, são interpretadas todas as falhas de interesse em sessões selecionadas pelo usuário. Para este estudo, foram realizadas interpretações manuais em 11 seções: 7 *inlines* e 4 *xlines*.

Foram realizadas duas rodadas independentes de aprendizado de máquina dentro desta metodologia, com diferentes rotulagens. Para ambas as rodadas, foi utilizado o dado sísmico “croppado” – cortado - no intervalo de 5000m a 9000m de profundidade, com o objetivo de atingir apenas o intervalo pré-sal do dado. Na primeira rodada, 7 *xlines* foram utilizadas como rótulo. Na segunda, foram somadas 4 *inlines* às mesmas 7 *xlines*. O resultado dessa operação será similar ao método pré-treinado, obtendo-se como produto um cubo de falhas; no entanto, espera-se resultados com qualidade mais elevada. Os produtos dessas rodadas são cubos de falhas.

Para a rotulagem, foram seguidas as seguintes recomendações de boas práticas para a interpretação de falhas:

- Idealmente, a rotulagem não deve passar de 2% do dado sísmico usado.
- A interpretação de falhas deve se estender verticalmente por todo o intervalo considerado.
- Linhas selecionadas para interpretação foram totalmente interpretadas.
- A rotulagem de falhas deve ser performada com alta resolução vertical para garantir que esta resolução seja preservada no modelo de predição.

- A interpretação deve ser conduzida em duas direções (*inline* e *xline*), preferencialmente em orientações perpendiculares às falhas para melhor visualização.

3.4.1. Primeira rodada

Para a primeira rodada de aprendizado de máquina, foi realizada a interpretação preliminar de falhas (figura 18) apenas em *xlines* e com dado sísmico de *input* realizado cortado no intervalo de interesse. Esta rodada se deu apenas em *xlines*, que estão dispostas na direção NE-SW, perpendicularmente à direção principal das estruturas geológicas (NW-SE) (figura 19).

➤ Interpretação preliminar de falhas

A interpretação sísmica foi realizada exclusivamente no intervalo correspondente ao pré-sal, delimitado entre 5000 m e 9000 m de profundidade. Foram interpretadas as seguintes *xlines*: 1490, 1558, 1580, 1600, 1705, 1795 e 1855 (figura 20).

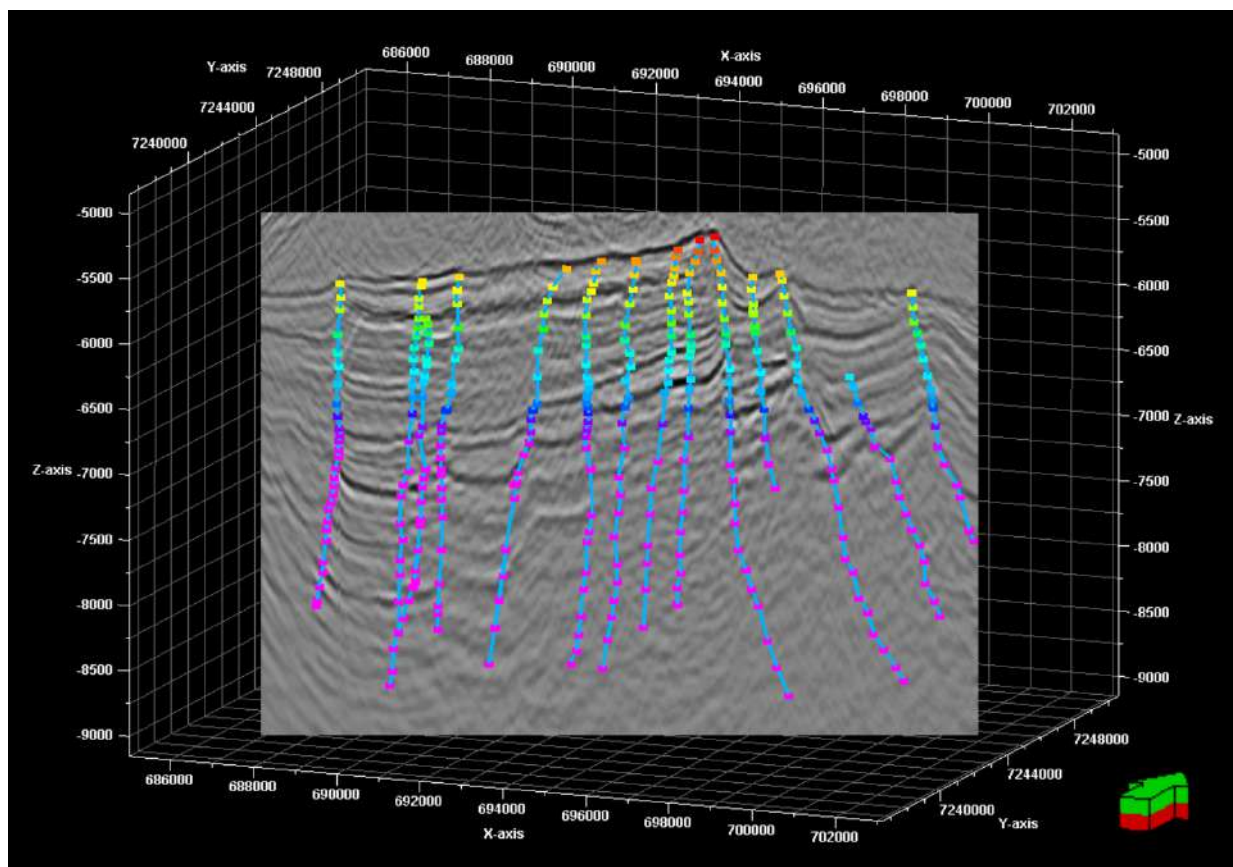


Figura 18: Rótulos da primeira rodada; *xline* 1558.




Figura 19: Rótulos da primeira rodada. Imagem em planta das linhas rotuladas sobrepostas à *depth slice* 7020.

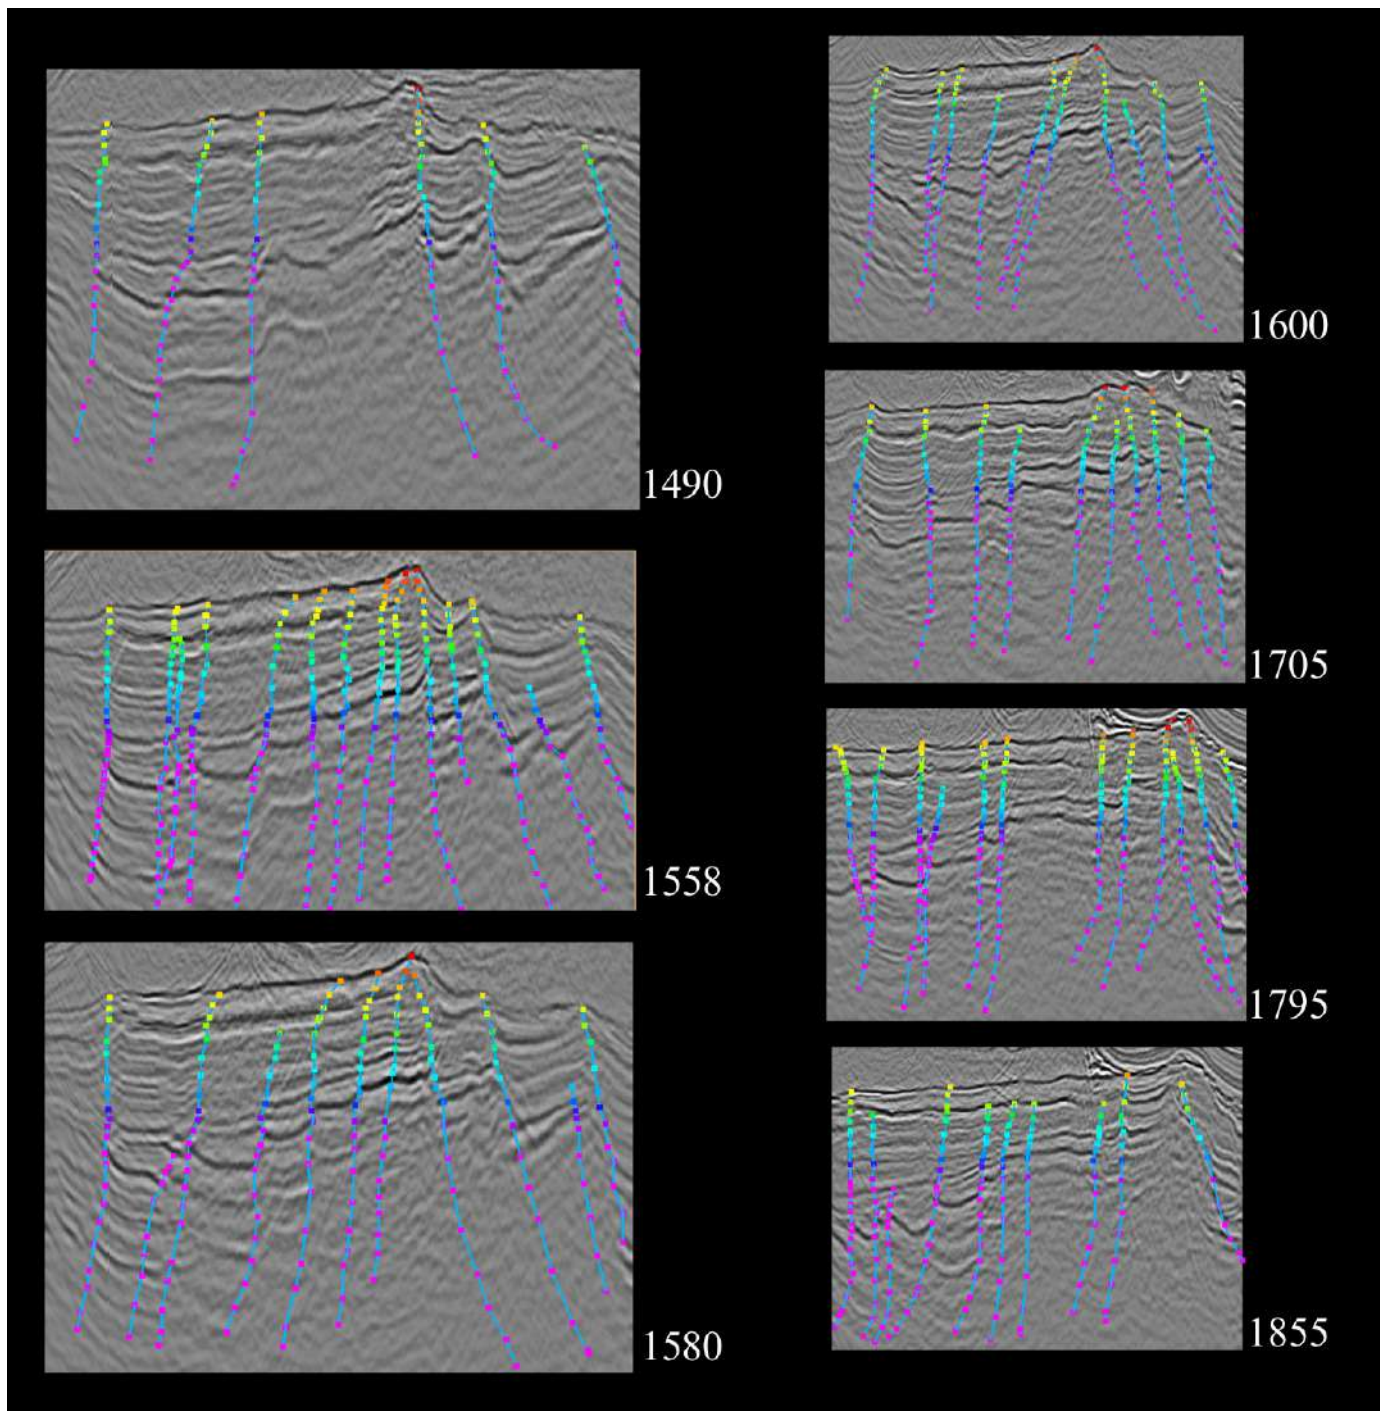


Figura 20: Rótulos da primeira rodada; representação das 7 *xlines* interpretadas.

➤ Criação do cubo de falhas

O cubo de falhas da primeira rodada treinada pelo usuário está representado nas figuras 21, 22 e 23.

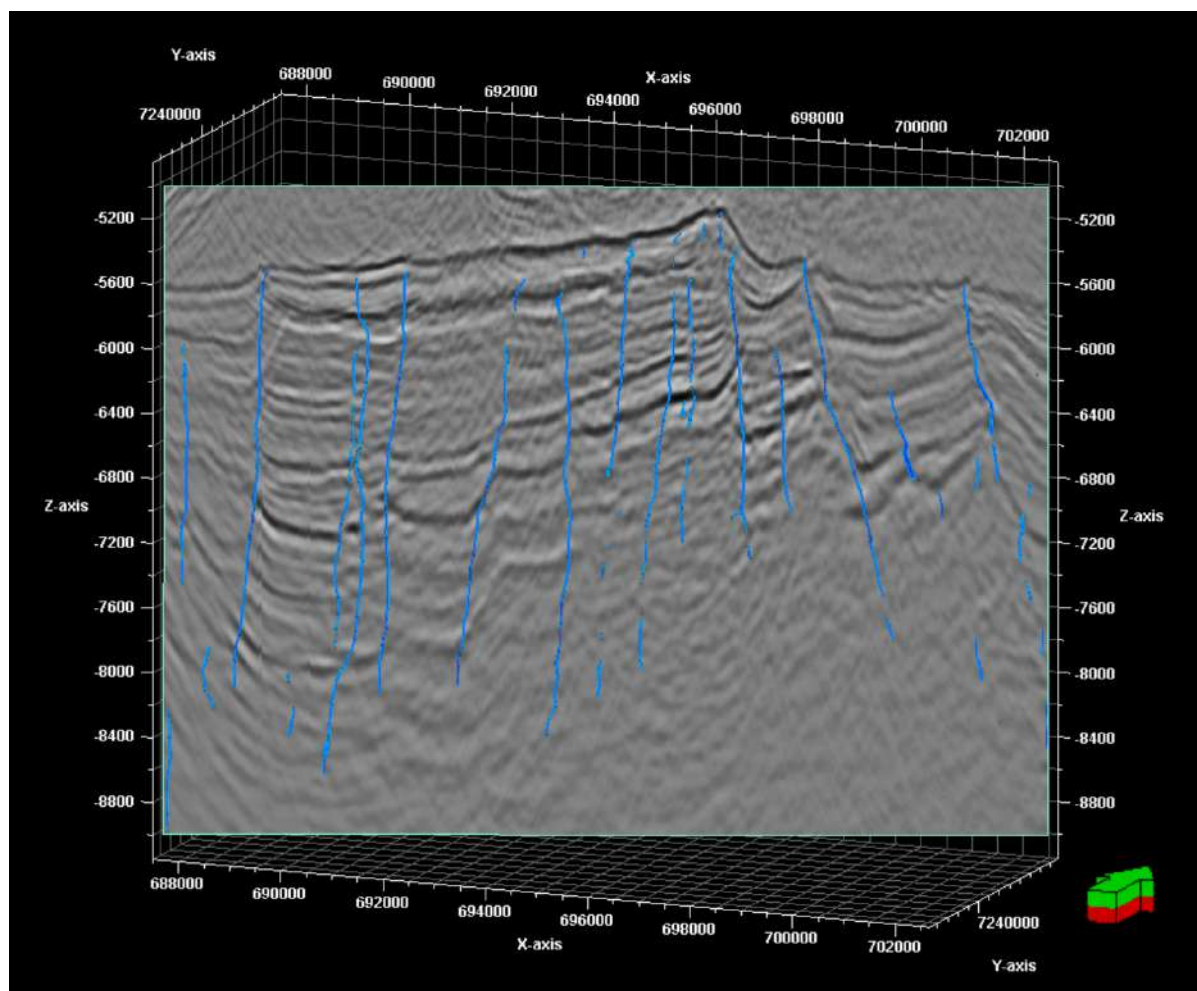


Figura 21: Cubo de probabilidade de falhas da primeira rodada; *xline* 1558.

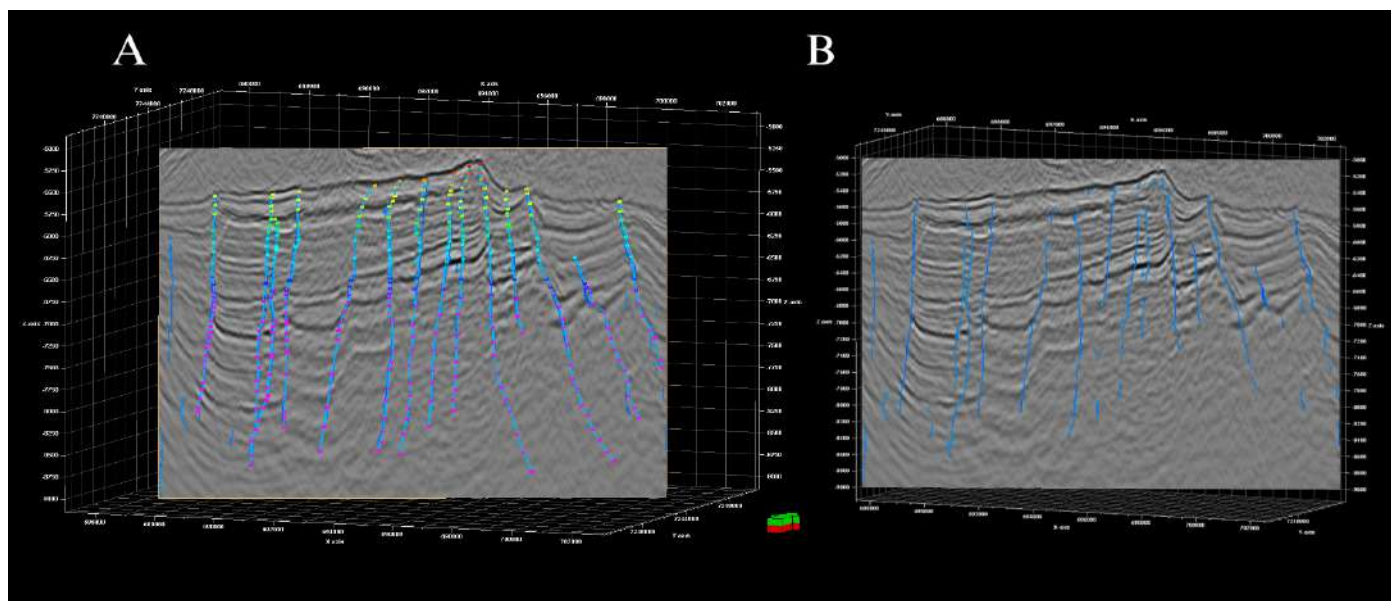


Figura 22: Comparação entre os rótulos e o cubo de probabilidade de falhas da primeira rodada.
Imagens da *xline* 1558. [A]: Rótulos sobrepostos ao cubo de falhas. [B]: Cubo de falhas.

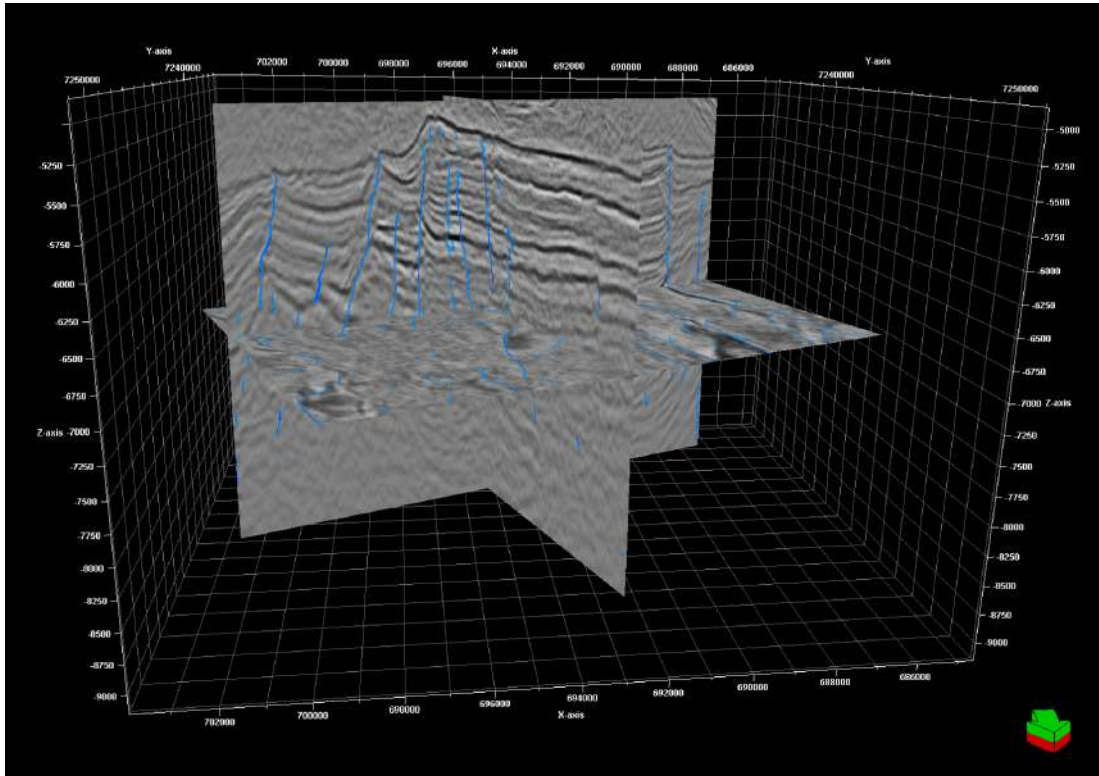


Figura 23: Cubo de falhas da primeira rodada; *xline*: 1558, *inline*: 7660, *z*: 7020.

➤ Extração de falhas em objetos de pontos e controle de qualidade dos pontos

Após a geração do cubo de falhas, procede-se à etapa de extração das falhas na forma de objetos de pontos, por meio da ferramenta *fault extraction*. Para essa etapa, utiliza-se como dado de entrada o cubo de falhas previamente gerado. Durante o processo, é possível configurar parâmetros como o *minimum threshold*, que define o tamanho mínimo dos voxels a serem interpretados como falhas — sendo que valores maiores resultam na identificação de um menor número de falhas —, e o *radius*, que corresponde à área de busca empregada na análise da continuidade das falhas. Para estes parâmetros, foram utilizados os valores em *default* pré-definidos pela aplicação.

A aplicação possibilita também o ajuste de alguns parâmetros (figura 24) de acordo com a necessidade do intérprete. São eles:

- **Parâmetros de extração:**

- Range de azimuth (*azimuth range*): usado para extrair as falhas considerando um range de azimuth específico
- Planaridade (*planarity*): é utilizado para dividir as falhas em suas respectivas interseções. Seus valores variam de 0 a 1, sendo que 0 indica ausência de planaridade — situação em que as falhas não seriam adequadamente separadas —, enquanto o valor 1 corresponde a regiões de falha totalmente planas.
- Tamanho mínimo de falha (*fault min. size*): remove falhas extraídas que possuem menos pontos que o valor especificado

- **Parâmetros avançados:**

- Tamanho do setor (*sector size*): usado para subdividir o range de azimuth definido em subsetores de azimuth, que podem ser sobrepostos.
- Sobreposição do setor (*sector overlap*): Sobreposição em graus que cada um dos subsetores sofre.
- Tamanho mínimo de *patch*: remove as falhas extraídas que são menores que o valor especificado.
- Sobreposição mínima (*min. overlap*): define a sobreposição mínima entre duas falhas que estão em subsetores vizinhos e representam a mesma falha.

Foram empregados dois conjuntos de parâmetros na extração: o *default*, correspondente ao padrão pré-estabelecido pela aplicação Petrel, e o conjunto definido pelo usuário (Figura 24), no qual foram realizados ajustes específicos pelo intérprete visando otimizar os resultados na extração dos objetos de pontos. Entre as modificações, destaca-se o aumento do parâmetro de planaridade de 0,55 para 0,62, com o intuito de favorecer a detecção de falhas com maior verticalidade, bem como a redução do tamanho mínimo de *patch* de 2000 para 500, visando aprimorar a resolução das falhas interpretadas.

Desta maneira, decidiu-se utilizar o conjunto de pontos extraídos com a parametrização do usuário , que apresentou um resultado de falhas mais condizente e coerente do que o conjunto extraído com parâmetros *default*.

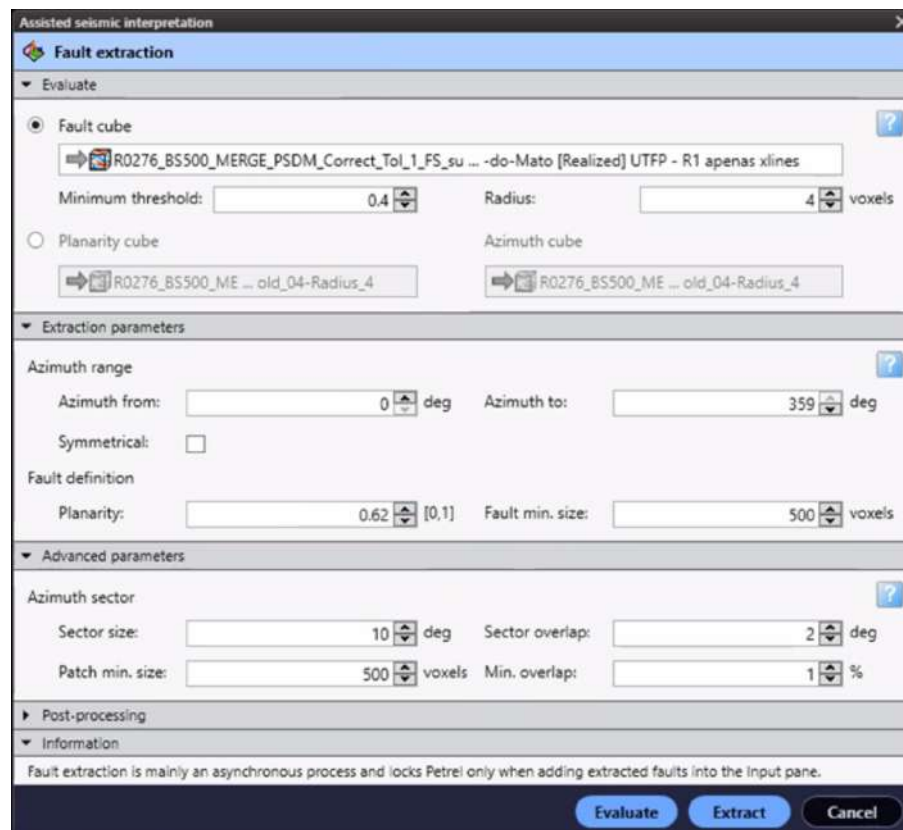


Figura 24: Janela *Fault Extraction* mostrando os parâmetros do usuário utilizados para a extração dos objetos de pontos.

Após a extração, torna-se necessária a etapa de controle de qualidade dos pontos extraídos, por meio da ferramenta de edição de pontos. Nessa fase, podem ser aplicados três tipos principais de edição: mesclagem (figura 25), separação e exclusão de pontos. Esses ajustes são fundamentais para garantir a coerência geológica das interpretações antes da

conversão dos *pointsets* em falhas. Assim, os *pointsets* extraídos e editados após o controle de qualidade estão exemplificados na figura 26.

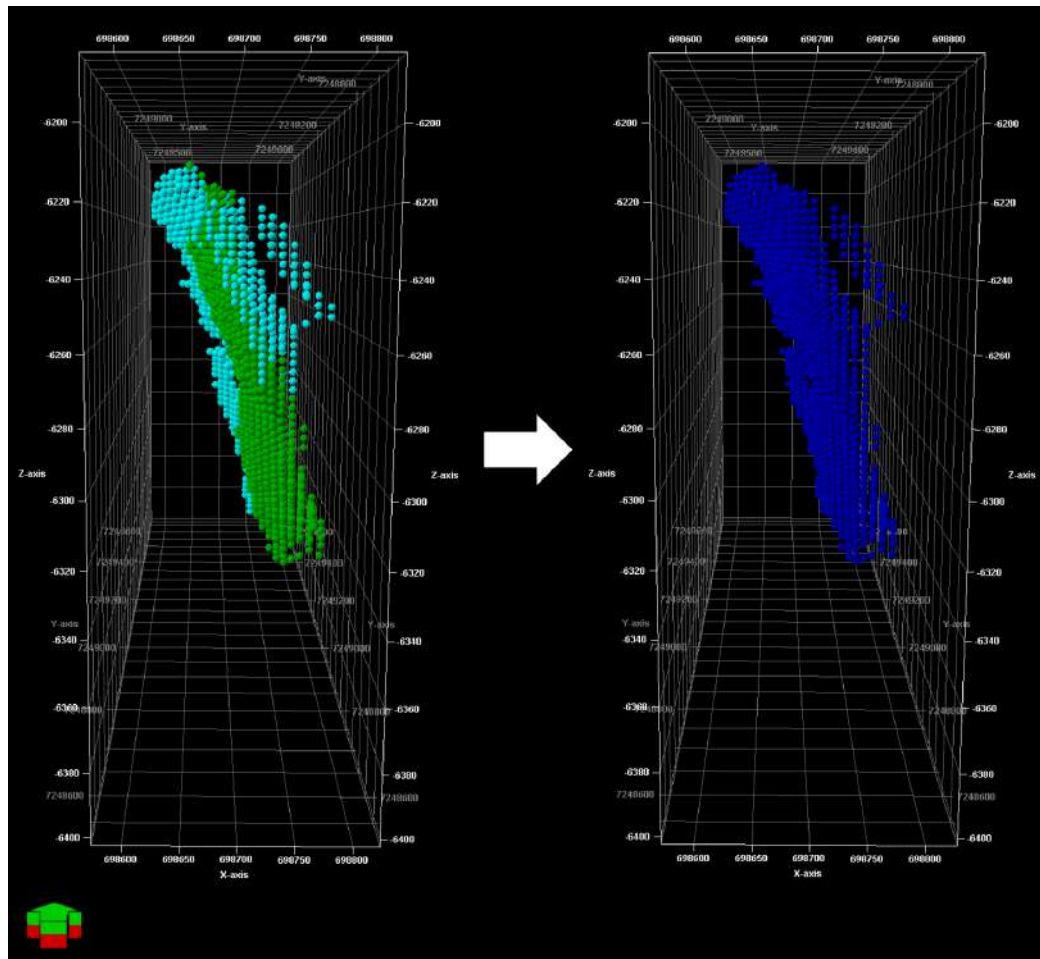


Figura 25: representação da operação de mesclagem de *pointsets*.




Figura 26: *Pointsets* resultantes da primeira rodada de machine learning após o controle de qualidade.

➤ Conversão dos pontos em objetos de interpretação

Após obter-se os *pointsets*, deve-se transformá-los em objetos de interpretação, que são os *fault sticks* (figura 27), que representam as falhas. Para isso, utiliza-se a janela *fault point set post processing*. A ferramenta possibilita também ajustar a distância em que os *fault sticks* e *nodes* serão extraídos; foram utilizados os valores *default* da aplicação: *fault stick distance* - 400 m - e *node distance* - 200 m.

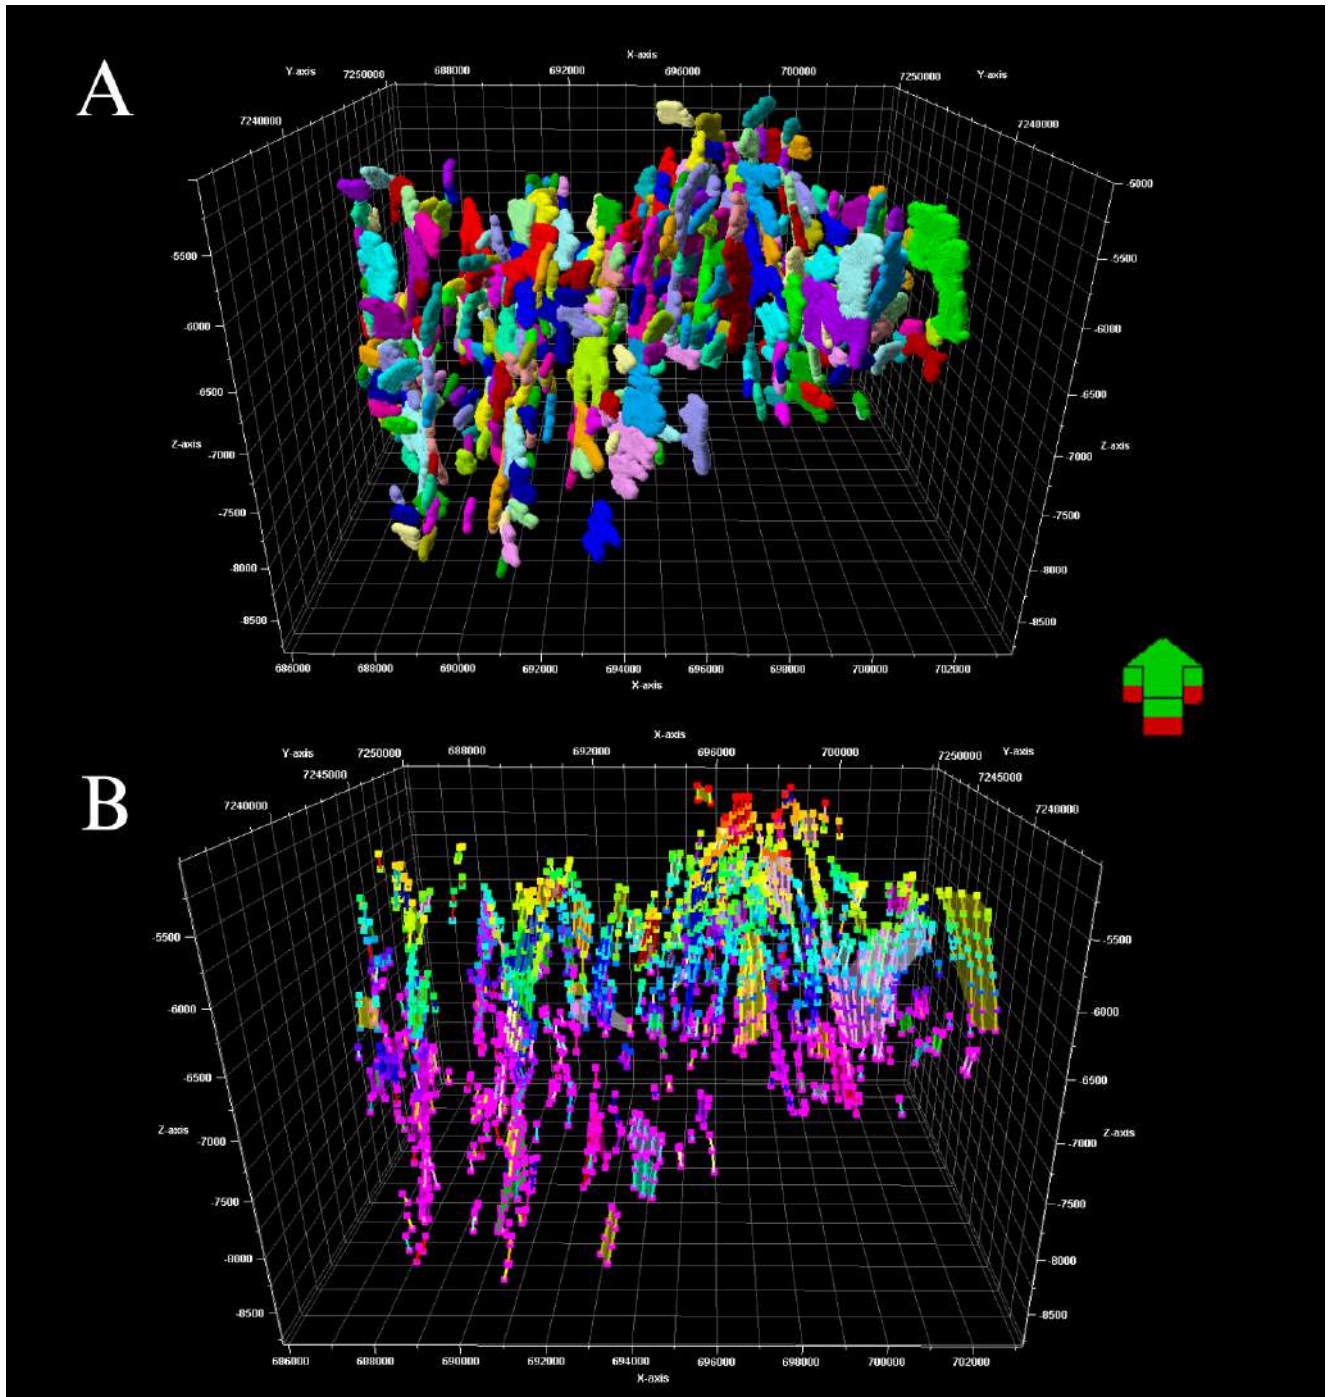


Figura 27: [A] *Pointsets* transformados em [B] *fault sticks*, resultantes da primeira rodada de machine learning após o controle de qualidade.

3.4.2. Segunda rodada

➤ Interpretação Preliminar de Falhas

Na segunda rodada, mantiveram-se as interpretações das *xlines* realizadas na etapa anterior. Entretanto, foram adicionadas interpretações em quatro *inlines*, com o objetivo de refinar o cubo de falhas. As *inlines* interpretadas foram: 7470, 7570, 7660 e 7870 (figuras 28 e 29).

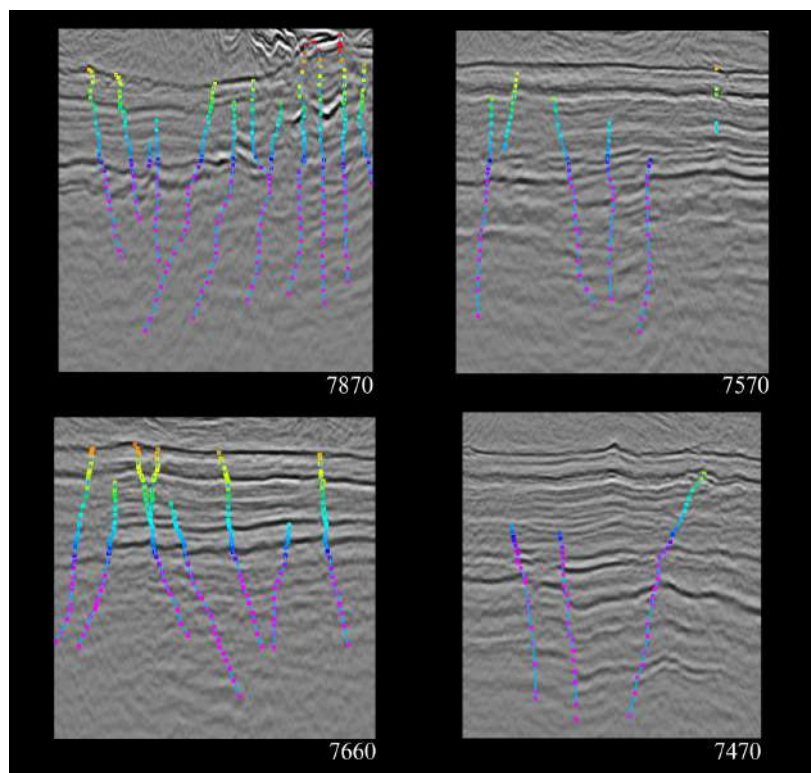


Figura 28: Rótulos da segunda rodada; *inlines* 7470, 7570, 7660 e 7870.




Figura 29: Rótulos da segunda rodada. Imagem em planta das 4 *inlines* interpretadas sobrepostas à *depth slice* 7020.

➤ Criação do Cubo de Falhas

O cubo de falhas da primeira rodada treinada pelo usuário está representado nas figuras 30 e 31.

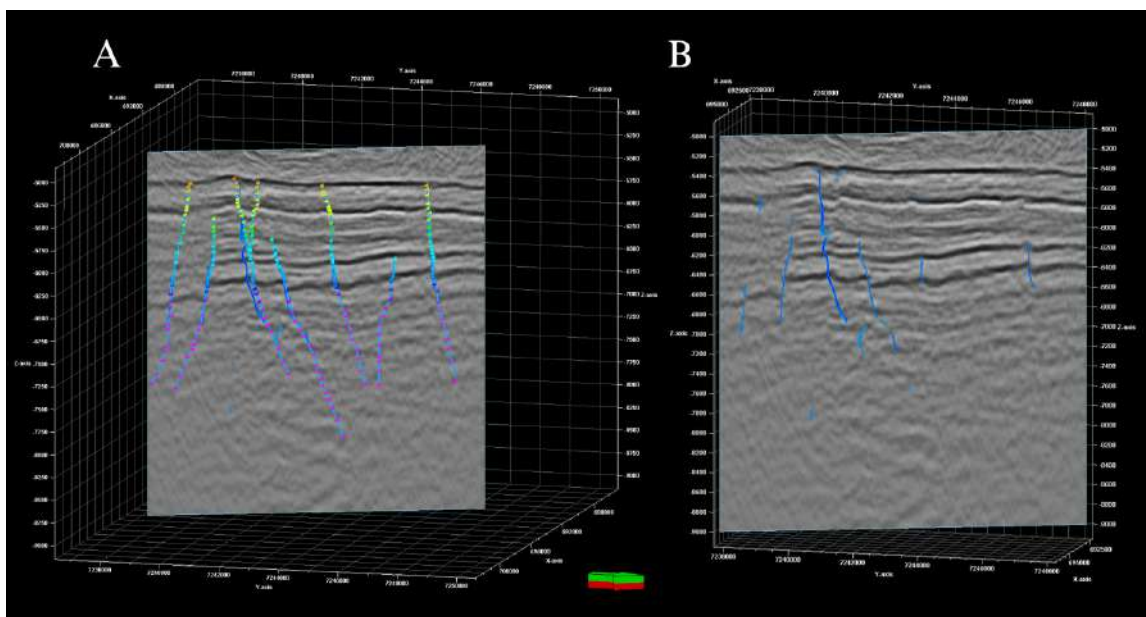


Figura 30: Comparação entre os rótulos e o cubo de probabilidade de falhas da segunda rodada. Imagens da *xline* 1558. [A]: Rótulos sobrepostos ao cubo de falhas. [B]: Cubo de falhas.

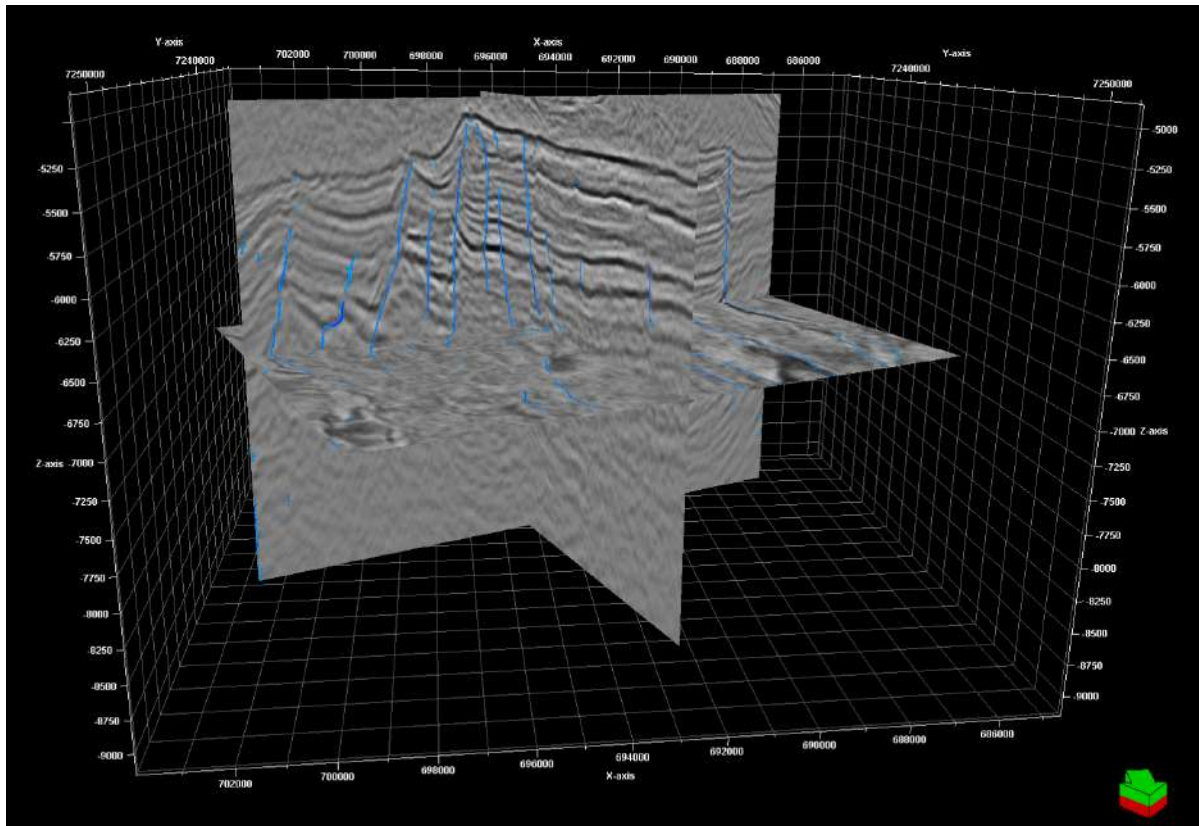


Figura 31: Cubo de falhas da segunda rodada; *xline*: 1558, *inline*: 7660, *z*: 7020.

➤ Extração de falhas em objetos de pontos e controle de qualidade dos pontos

Para esta etapa, foram mantidos os procedimentos da primeira rodada. Os parâmetros de *minimum threshold* e *radius* foram mantidos em default. O controle de qualidade foi realizado levando em consideração os mesmos critérios de coerência geológica. Assim, os *pointsets* estão representados na figura 32.

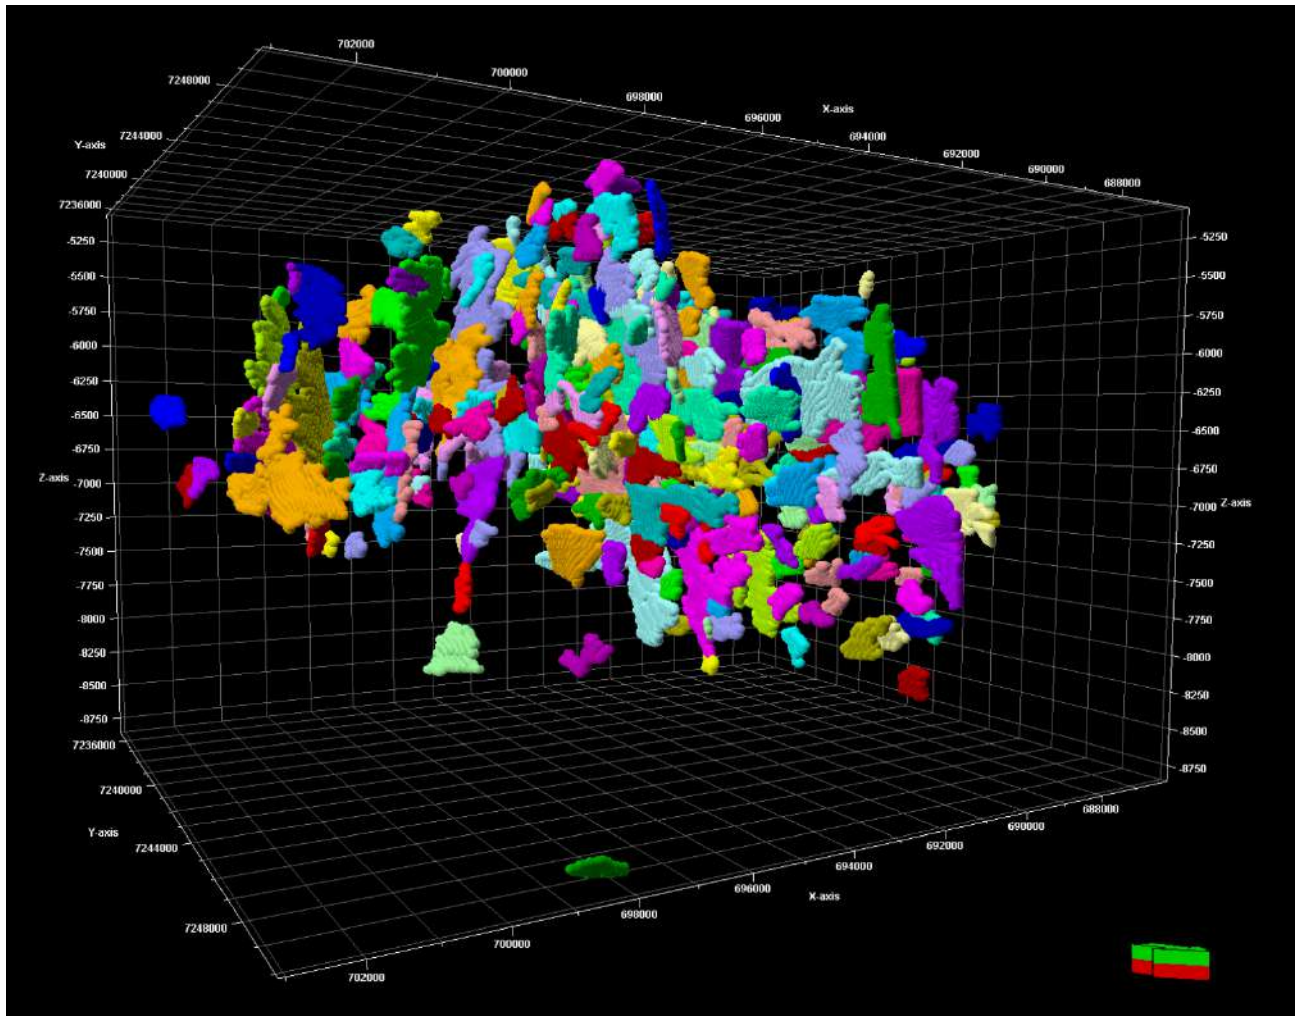



Figura 32: *Pointsets* resultantes da segunda rodada de *machine learning* após o controle de qualidade.

➤ Conversão dos pontos em objetos de interpretação

Para esta etapa, foram mantidos os procedimentos da primeira rodada. As alterações nos parâmetros de planaridade - de 0,55 para 0,62 - e tamanho mínimo de *patch* - de 2000

para 500 - foram mantidas. A figura 33 ilustra os *pointsets* e os *faultsticks* em comparação.

A



B

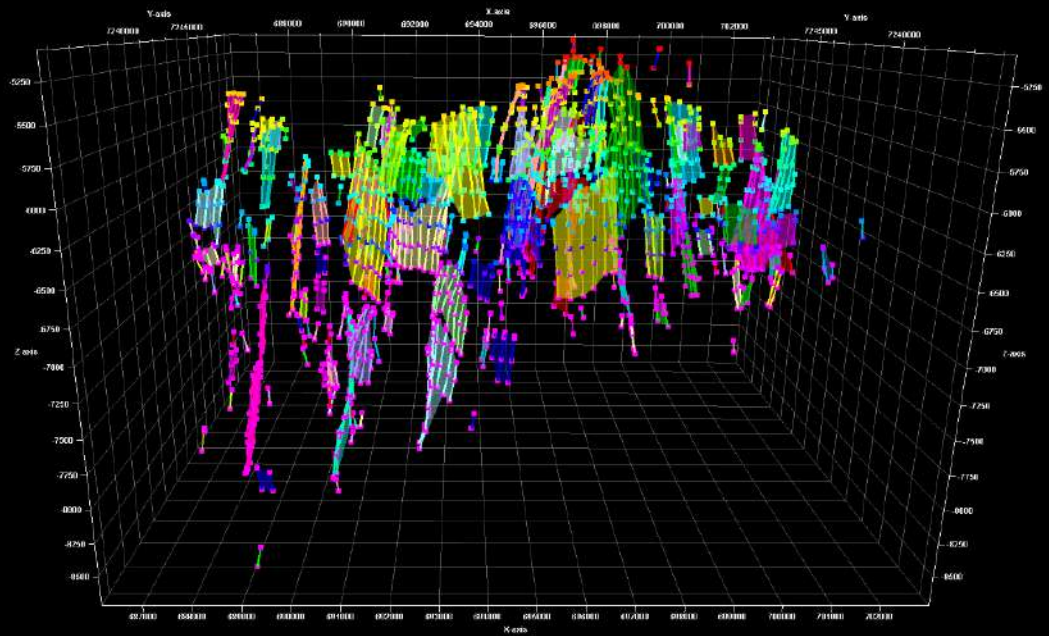


Figura 33: [A] *Pointsets* transformados em [B] *fault sticks*, resultantes da segunda rodada de *machine learning* após o controle de qualidade.

4. RESULTADOS

4.1. Resultados da metodologia pré treinada

Os *pointsets* resultantes da metodologia pré-treinada estão representados na figura 34.




Figura 34: *Pointsets* resultantes da metodologia pré-treinada sobreposto à *xline* 1558.

4.2. Resultados da metodologia treinada pelo usuário - primeira rodada

Extraíram-se 536 falhas através da metodologia e, após o controle de qualidade, foram obtidas 477 falhas. O estereograma plotado com as falhas da primeira rodada demonstra três *trends* estruturais com direções N/S, NW/SE e NE/WS (figura 35). Os *faultstickts* resultantes da primeira rodada da metodologia treinada pelo usuário estão representados na figura 36.

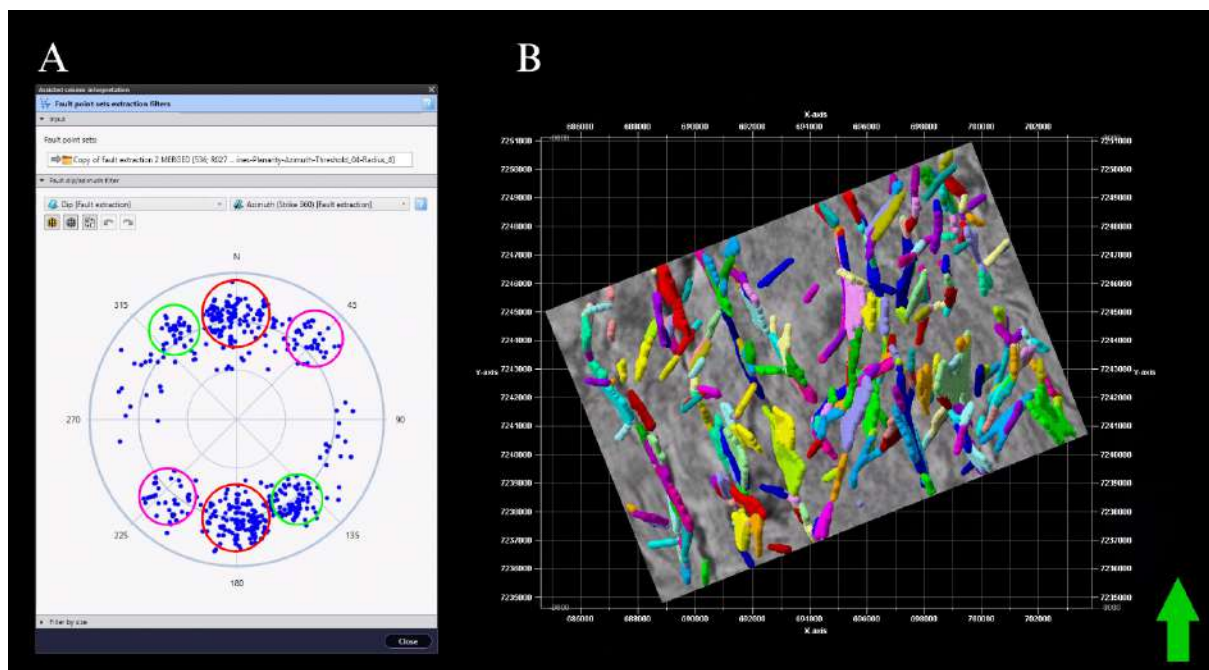


Figura 35: [A] Estereograma plotado com as falhas da primeira rodada; observa-se três *trends* estruturais: N/S (destacado em vermelho), NW/SE (destacado em verde) e NE/SW (destacado em rosa); [B] *pointsets* resultantes da primeira rodada sobrepostos à *depthslice* 7020.




Figura 36: Resultados da metodologia treinada pelo usuário - primeira rodada; [A] *faultsticks* sobrepostos à *depthslice* 7020, [B] *faultsticks* vistos em 3D.

4.3. Resultados da metodologia treinada pelo usuário - segunda rodada

Extraíram-se 352 falhas através desta metodologia e, após o controle de qualidade, foram obtidas 279 falhas. O estereograma plotado com as falhas da segunda rodada demonstra, mais uma vez, três *trends* estruturais com direções N/S, NW/SE e NE/WS (figura 37). Os *faultstickts* resultantes da segunda rodada da metodologia treinada pelo usuário estão representados na figura 38.

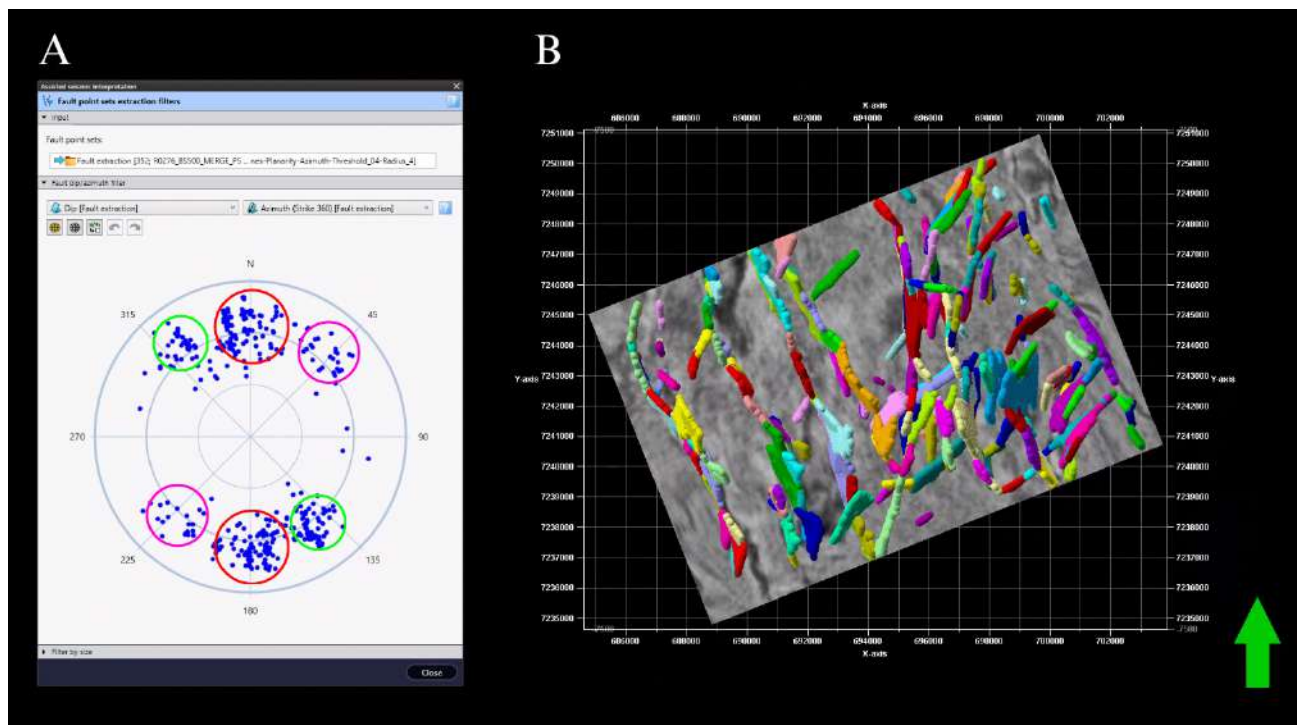


Figura 37: [A] Estereograma plotado com as falhas da segunda rodada; observa-se três *trends* estruturais: N/S (destacado em vermelho), NW/SE (destacado em verde) e NE/SW (destacado em rosa); [B] *pointsets* resultantes da segunda rodada sobrepostos à *depthslice* 7020.

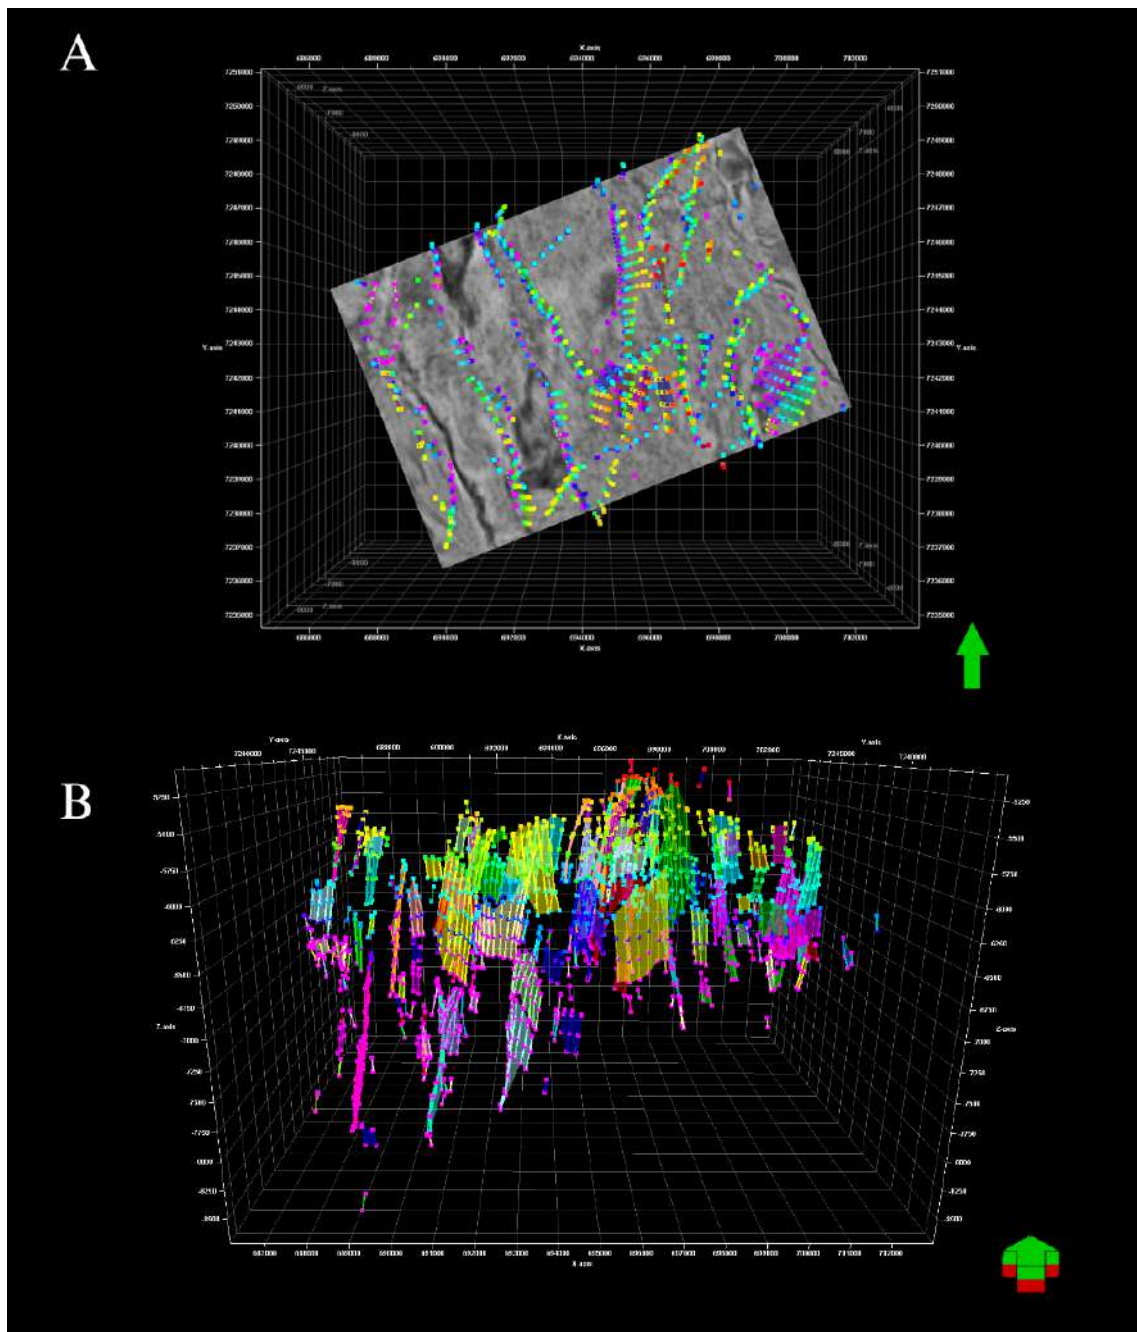


Figura 38: Resultados da metodologia treinada pelo usuário - segunda rodada; [A] faultsticks sobrepostos à *depthslice* 7020, [B] faultsticks vistos em 3D.

5. DISCUSSÕES

5.1. Metodologia pré-treinada

A metodologia pré-treinada não apresentou resultados satisfatórios, uma vez que não obteve sucesso no reconhecimento de padrões estruturais e estratigráficos característicos da região do pré-sal. Já se previa que o modelo final apresentasse limitações em sua adaptação ao contexto do pré-sal. Uma razão para isso é o fato de não ter havido um treinamento específico da aplicação para a geologia da região, já que as redes neurais convolucionais (CNN) operam por meio da replicação de exemplos gráficos. Isso comprometeu a capacidade do modelo em identificar adequadamente as feições geológicas. Outro motivo é a relativa baixa qualidade do dado sísmico, especialmente no intervalo do pré-sal, onde existem distorções dos tipos *pull down* e *pull up* por conta da espessa camada de sal que sobrepõe a área estudada.

5.2. Metodologia treinada pelo usuário

Considerando que a interpretação sísmica é uma tarefa predominantemente manual, de longa duração e altamente dependente da qualidade de dados sísmicos disponíveis, os resultados obtidos permitem algumas reflexões.

- 1) *Coerência geológica*: a metodologia treinada pelo usuário apresentou resultados satisfatórios, com boa coerência geológica e em conformidade com os rótulos fornecidos como *input*. As falhas extraídas apresentaram concordância de tendência estrutural com as observadas na literatura.
- 2) *Redução de esforço*: a metodologia também demonstrou ampla cobertura do cubo sísmico, realizando interpretações em todas as linhas sísmicas. Assim, a inteligência artificial aparenta ser uma ferramenta promissora para mitigar o

grande esforço manual demandado por esta atividade, uma vez que reduz a necessidade de interpretar grande quantidade de seções, resultando em menor tempo despendido no processo interpretativo. Essa vantagem torna-se ainda mais relevante nas fases exploratórias, nas quais são utilizados grandes volumes de dados sísmicos e elaborados modelos em escala de bacia. Entretanto, é preciso ressaltar que as seções foram parcialmente interpretadas pela ferramenta e, sendo assim, o intérprete ainda necessita complementar as interpretações realizadas pela inteligência artificial.

- 3) *Redução do tempo de interpretação*: o fluxo utilizando aprendizado de máquina parece ser uma solução parcial para o problema da longa duração do fluxo de trabalho de interpretação sísmica. A ferramenta permite a interpretação em alguns minutos de volumes sísmicos que seriam interpretados em dias pelo fluxo convencional. Destaca-se, ainda, a vantagem de se interpretar um número reduzido de linhas — por exemplo, 11 linhas — e, a partir delas, obter interpretações em aproximadamente 600 linhas adicionais. Entretanto, o resultado final do fluxo demanda um volume significativo de correções. Em outras palavras, há uma substituição do tempo originalmente dedicado à interpretação direta pelo tempo necessário para ajustes e validações dos resultados gerados automaticamente. Percebeu-se, portanto, uma demanda considerável de tempo para o controle de qualidade dos resultados, o que indica que, embora promissora, a solução de aprendizado de máquina não elimina completamente as limitações relacionadas ao tempo de geração do modelo.

- 4) *Qualidade do dado sísmico*: a ferramenta pode representar uma solução parcial para o problema da qualidade dos dados sísmicos. A aplicação mostrou-se promissora na detecção de falhas não identificadas pelo intérprete em áreas de baixa amplitude (figura 39). Entretanto, a ferramenta ainda apresenta limitações, sintetizadas no princípio “*garbage in, garbage out*”, segundo o qual a qualidade do resultado final está diretamente relacionada à qualidade dos dados de entrada (Sheposh, 2024). Ressalta-se que esta não é uma ferramenta de aumento de resolução sísmica e, assim como depende do *input* de rótulos geologicamente coerentes para o treinamento, requer dados sísmicos de boa amplitude para a geração de um modelo confiável.
- 5) *Geometria das falhas*: os resultados obtidos por meio da metodologia treinada pelo usuário solucionam a limitação geométrica observada nas falhas interpretadas manualmente por *picking*, as quais tendem a apresentar menor precisão, resultando em geometrias excessivamente retilíneas e angulosas, que não refletem adequadamente a realidade geológica. Em contraste, as falhas geradas pela metodologia de machine learning apresentam maior suavidade, respeitando de forma mais fiel as características da geologia local.
- 6) *Rotulagem em duas direções*: observou-se que os pointsets obtidos na primeira rodada de machine learning foram gerados em maior quantidade (52,27% a mais de falhas que na segunda rodada). Uma razão para isso é a apresentando fragmentação das falhas. Assim, a descontinuidade das falhas demandou considerável esforço de correção por meio de mesclagem. Por outro lado, os *pointsets* resultantes da segunda rodada apresentaram maior coerência em termos de conectividade e continuidade. Esses resultados indicam que o uso de

rótulos em ambas as direções (*xlines* e *inlines*) contribui para interpretações mais eficazes, garantindo maior consistência geológica ao modelo final.




Figura 39: Comparação entre os rótulos e o cubo de probabilidade de falhas da primeira rodada, imagem da *xline* 1558. Rótulos sobrepostos ao cubo de falhas. Destaque para a identificação de uma falha que não foi percebida pelo intérprete em uma região ruidosa.

Adicionalmente, alguns procedimentos podem ser adotados com o objetivo de aprimorar os resultados obtidos por meio desse fluxo de trabalho. Recomenda-se o condicionamento prévio do dado sísmico por meio da aplicação de atributos, como *structural smoothing* e *chaos*, de modo a ressaltar as feições estruturais e, conseqüentemente, proporcionar uma interpretação mais confiável. Recomenda-se também uma maior

experimentação dos parâmetros utilizados na extração de falhas. A avaliação sistemática de diferentes configurações de parametrização pode ser especialmente útil para a definição dos valores mais adequados às especificidades da área de estudo, potencializando o desempenho e a eficácia da ferramenta de inteligência artificial.

Por exemplo, neste trabalho, as mudanças de parametrização realizadas para extrair os *pointsets* permitiu a seguinte comparação entre os resultados, demonstrada na tabela xxx:

Rodadas	Parâmetros <i>default</i>	Parâmetros usuário
Rodada 1	83 <i>pointsets</i>	536 <i>pointsets</i>
Rodada 2	79 <i>pointsets</i>	352 <i>pointsets</i>

Tabela 1: Parâmetros em *default* e alterados utilizados nas rodadas 1 e 2 de aprendizado de máquina.

Observa-se que, para as duas rodadas, os ajustes nos parâmetros aumentaram consideravelmente a quantidade de *pointsets* extraídos. Isso se deu por conta do aumento da verticalidade e da resolução dos *patches*. Isto resolve o problema que é a pequena quantidade de falhas extraídas com os parâmetros em *default*. Por outro lado, notou-se que os *pointsets* apresentaram maior segmentação, onde algumas falhas perderam conectividade e dividiram-se em vários objetos de pontos. Por essa razão, realizou-se o controle de qualidade dos *pointsets* e a mesclagem de alguns destes através da ferramenta *fault point set editing*, com o objetivo de conferir maior continuidade das falhas.

6. CONCLUSÕES

A atividade de interpretação sísmica tem como objetivo final gerar um modelo que seja representativo da subsuperfície, coerente com a geologia regional e que permita a previsibilidade geológica da área de estudo. Nesse contexto, a inteligência artificial foi eficaz no cumprimento deste objetivo, configurando-se como uma metodologia eficiente e com potencial para aprimorar os fluxos de interpretação sísmica. Conclui-se, portanto, que a aplicação de inteligência artificial utilizada neste trabalho se mostrou uma ferramenta promissora, com potencial para, à medida que for aprimorada, representar uma verdadeira mudança de paradigma na atuação dos geocientistas. A ferramenta foi satisfatória dentro do que se propõe e, de fato, otimizou etapas do fluxo tradicional de interpretação, entregando um modelo com coerência geológica dentro do que lhe foi dado como *input*.

Entretanto, destaca-se a importância do intérprete enquanto guia da ferramenta, tanto para a boa rotulagem quanto para as parametrizações que o fluxo de trabalho possibilita e para as correções necessárias nas etapas de controle de qualidade. O próprio conceito destacado no nome da técnica - aprendizado de máquina - evidencia sua natureza dependente de dados de entrada qualificados. Assim como um aluno, que carece de um bom professor que tenha um conteúdo de qualidade para lhe fornecer, a inteligência artificial depende da expertise do profissional de geociências para o fornecimento de dados adequados, possibilitando, assim, interpretações mais precisas e geologicamente consistentes.

Além da rotulagem com qualidade, a aplicação de inteligência artificial também requer critérios rigorosos para a avaliação dos resultados obtidos, tarefa que permanece sob a responsabilidade dos intérpretes. Embora a utilização dessas ferramentas proporcione uma significativa redução no esforço manual necessário para gerar grandes volumes de falhas, os geocientistas permanecem como agentes indispensáveis no processo, pois são os detentores do conhecimento técnico e do senso crítico necessários para validar as interpretações geradas pela máquina. As etapas de parametrização e controle de qualidade — mesclagem, separação

e exclusão de falhas ou estruturas incoerentes — mostraram-se fundamentais para a robustez do modelo final, mesmo demandando um tempo considerável para sua execução.

Dessa forma, a assistência proporcionada pela inteligência artificial parece ser promissora no campo das geociências, além de já representar uma realidade consolidada no mercado de óleo e gás. O estabelecimento de tais ferramentas pode vir a implicar na necessidade de adaptações nos fluxos de trabalho dos geocientistas, bem como uma potencial reconfiguração do papel dos intérpretes, que passam a atuar de forma mais direcionada na análise crítica, validação e complementação das interpretações produzidas por algoritmos de aprendizado de máquina.

7. REFERÊNCIAS

ANP. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. 2ª Rodada de Partilha da Produção - Sumário Executivo das Áreas em Oferta, 2017.

ANP. Agência Nacional do Petróleo, Gás Natural E Biocombustíveis. Boletim da Produção de Petróleo e Gás Natural - 2023. Encarte de Consolidação da Produção 2023, [s. l.], 2023.

BELYADI, Hoss; HAGHIGHAT, Alireza. Machine Learning Guide for Oil and Gas Using Python: A Step-by-Step Breakdown with Data, Algorithms, Codes, and Applications. [S. l.: s. n.], 2021.

BORGES , Tom Araujo; GAMBÔA, Luiz Antonio Pieranttoni. Sismoestratigrafia do limite sul da Bacia de Santos e suas implicações na evolução do Atlântico Sul primordial. Boletim de Geociências da Petrobras, Rio de Janeiro, v. 23, 2015.

CARVALHO, Renato Kramberger; MELLO, Claudio Limeira; JUNIOR, Olinto Gomes de Souza. Caracterização e restauração estrutural de uma área do Pré-sal da Bacia de Santos e o impacto da paleogeografia no controle da deposição das fácies no reservatório. Revista do Instituto de Geociências - USP, São Paulo, ano 2024, v. 24, ed. 1, p. 51-72, 2024. <https://doi.org/10.11606/issn.2316-9095.v24-200523>

CHANG, H. K.; ASSINE, M. L.; CORREA, F. S.; TINTEN, J. S.; VIDAL, A. C.; KOIKE, L. Sistemas petrolíferos e modelos de acumulação de hidrocarbonetos na Bacia de Santos, 38, n. 2, p 29–46, 2008.

CPRM. Geologia e Recursos Minerais do Estado do Rio de Janeiro. Geologia e recursos minerais do Estado do Rio de Janeiro: texto explicativo do mapa geológico e de recursos minerais. / Monica Heilbron, Luiz Guilherme do Eirado, Julio Almeida Orgs. Belo Horizonte: [s. n.], 2016. cap. 2, p. 19-21.

DEPREZ, Maria; ROBINSON, Emma C. Convolutional neural networks. In: MACHINE Learning for Biomedical Applications. [S. l.: s. n.], 2024. cap. 11, p. 233-270. ISBN 9780128229040

DIAS, Jeferson Luiz. Tectônica, estratigrafia e sedimentação no Andar Aptiano da margem leste brasileira. Boletim de Geociências da Petrobras, Rio de Janeiro, v. 13, ed. 1, p. 7-25, 2005.

GUO, Yinling; PENG, Suping; DU, Wenfeng; LI, Dong. Fault and horizon automatic interpretation by CNN: a case study of coalfield. Journal of Geophysics and Engineering, [s. l.], ano 2020, v. 17, ed. doi:10.1093/jge/gxaa060, p. 1016–1025, 28 out. 2020.

HEILBRON, Monica et al. Província Mantiqueira. Geologia do continente sul-americano: : evolução da obra de Fernando Flávio Marques de Almeida. Tradução . São Paulo: Beca, 2004. Disponível em: <https://repositorio.usp.br/directbitstream/57c852c0-fdc0-4357-82ad-a682d4a5e32a/1417383.pdf>. Acesso em: 16 jul. 2025

JUNIOR, Arnaldo de Carvalho. Redes Neurais Artificiais: Algoritmos poderosos para aplicações de IA e ML. Laboratório de Inteligência Artificial Embarcada; Instituto Federal de São Paulo, 3 abr. 2024. Disponível em: <https://eailab.labmax.org/2024/04/03/redes-neurais-artificiais-algoritmos-poderosos-para-aplicacoes-de-ia-e-ml/>. Acesso em: 30 jun. 2025.

KARNER G.D.; DRISCOLL N.W. Tectonic and stratigraphic development of the West African and eastern Brazilian margins, insights from quantitative basin modelling. Geological Society, London, Special Publication, 153, p 11–40, 1999.

KUKLA, P. A.; STROZYK, F.; MOHRIAK, W. U. South Atlantic salt basins–witnesses of complex passive margin evolution. Gondwana Research, v. 53, p. 41-57, 2017.

LECUN, Y. et al. Gradient-based learning applied to document recognition. Proceedings of the IEEE, v. 86, n. 11, p. 2278–2323, 1998. ISSN 00189219.

Lorentzen, M. C. L., Bredesen, K., Smit, F. W. H., Hansen, T. H., Nielsen, L. and Mosegaard, K. 2022: Mapping Cretaceous faults using a convolutional neural network – A field example from the Danish North Sea. *Bulletin of the Geological Society of Denmark*, Vol. 71, pp. 31–50. ISSN 2245-7070. <https://doi.org/10.37570/bgsd-2022-71-03>

MCCULLOCH , Warren S; PITTS, Walter. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, [s. l.], v. 5, p. 115-133, 1943.

MOHRIAK, W. U., J. M. Macedo, R. T. Castellani, H. D. Rangel, A. Z. N. Barros, M. A. L. Latgé, J. A. Ricci, A. M. P. Mizusaki, P. Szatmari, L. S. Demercian, J. G. Rizzo, and J. R. Aires. Salt tectonics and structural styles in the deep water province of the Cabo Frio region, Rio de Janeiro, Brazil, in M. P. A. Jackson, D. G. Roberts, and S. Snelson, eds., *Salt tectonics: a global perspective: AAPG Memoir 65*, p. 273–304, 1995.

MOHRIAK, W. U. 2004. Recursos energéticos associados à ativação tectônica mesozóico-cenozóica da América do Sul. In: V. Mantesso – Neto, A. Bartorelli,

MOHRIAK, W. U. & PAULA, O. B. 2005. Major tectonic features in the southeastern Brazilian margin. 9th International Congress of the Brazilian Geophysical Society, Salvador, Brasil, 2005. Carneiro and B.B.Brito-Neves (eds.), *Geologia do continente sul-americano: evolução da obra de Fernando Flávio Marques de Almeida*, cap. XVIII, 293 – 318.

MOREIRA, J. L. P.; MADEIRA, C. V.; GIL, J. A.; MACHADO, M. A. P. Bacia de Santos. *Boletim de Geociências da Petrobras* 15, p 531–549, 2007.

PEREIRA, M. J. & FEIJÓ, F. J. Bacia de Santos. *Estratigrafia das Bacias Sedimentares do Brasil*. 1994.

PEREIRA, M. J. & MACEDO, J. M. Santos Basin: the outlook for a new petroleum province on the Southeastern Brazilian continental shelf; A Bacia de Santos: perspectivas de uma nova província petrolífera na plataforma continental sudeste brasileira. 1990

RICCOMINI, C.; SANT'ANNA, L. G.; TASSINARI, C. C. G. Pré-sal: geologia e exploração. Revista Usp, n. 95, p. 33-42, 2012.

SHEPOSH, Richard. Garbage in, garbage out (GIGO). In: EBSCO. Garbage in, garbage out (GIGO). [S. l.], 18 nov. 2024. Disponível em: <https://www.ebsco.com/research-starters/computer-science/garbage-garbage-out-gigo>. Acesso em: 10 jul. 2025.

SILVA, Raísa Carvalho. Construção de um modelo tectonoestratigráfico com foco no reservatório carbonático do pré-sal do prospecto de Gato do Mato, Bacia de Santos. 2021. Dissertação (Mestrado em Geologia e Geofísica) - Universidade Federal Fluminense, [S. l.], 2021.

VISHAL, D., AHINOAM, P., URI, W. & TAPAN, M., 2018. Convolutional neural network for seismic impedance inversion, SEG International Exposition and 88th Annual Meeting, pp. 2071–2075.

WALDELAND, A.U., JENSEN, A.C., GELIUS, L.J. & SOLBERG, A.H.S., 2018. Convolutional neural networks for automated seismic interpretation, The Leading Edge, 37, 529–537

WRIGHT, V. P.; BARNETT, A. J. An abiotic model for the development of textures in some South Atlantic early Cretaceous lacustrine carbonates. Geological Society, London, Special Publications, 418 (1), p 209–219, 2015.

ZHAO, T., 2018. Seismic facies classification using different deep convolutional neural networks, SEG International Exposition and 88th Annual Meeting, pp. 2046–2050.