



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS MATEMÁTICAS E DA NATUREZA
INSTITUTO DE GEOCIÊNCIAS

Julia Machado Magaldi

**AVALIAÇÃO DE DESEMPENHO E DIAGNÓSTICO DE ERROS NA AUTOMAÇÃO
DO AJUSTE DE PROFUNDIDADE DE AMOSTRAS LATERAIS**

Rio de Janeiro
2026

Julia Machado Magaldi

AVALIAÇÃO DE DESEMPENHO E DIAGNÓSTICO DE ERROS NA AUTOMAÇÃO
DO AJUSTE DE PROFUNDIDADE DE AMOSTRAS LATERAIS

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
Geóloga.

Orientador: Prof. Francisco Tognoli

Rio de Janeiro

2026

Julia Machado Magaldi

AVALIAÇÃO DE DESEMPENHO E DIAGNÓSTICO DE ERROS NA AUTOMAÇÃO
DO AJUSTE DE PROFUNDIDADE DE AMOSTRAS LATERAIS

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
Geóloga.

Rio de Janeiro, 02 de junho de 2026.

Prof. Dr. Francisco Manoel Wohnrath Tognoli - Orientador
Universidade Federal do Rio de Janeiro (UFRJ)

Prof. Dr. Marcelo Barbosa – Membro Interno
Universidade Federal do Rio de Janeiro (UFRJ)

Dr^a. Julia Favoreto – Membro Externo
Universidade Federal do Rio de Janeiro (UFRJ)

Dedico esse trabalho à Julia do futuro, você é capaz.

AGRADECIMENTOS

Agradeço, primeiramente, à minha família, pelo suporte e pelas condições que possibilitaram toda a minha trajetória acadêmica, pela compreensão nos momentos de ausência e pela confiança em mim, mesmo nos períodos mais desafiadores. Foram fundamentais para que eu chegasse até aqui.

Aos professores e professoras do curso, pelas contribuições ao longo da graduação, essenciais para minha formação acadêmica e profissional. Em especial, ao meu orientador, pelos incentivos e pela confiança depositada em minha capacidade desde o início desta pesquisa.

Agradeço a todos que fizeram parte da minha trajetória acadêmica, cujas experiências e aprendizados foram determinantes para a construção deste percurso.

Manifesto meu agradecimento especial àqueles que contribuíram diretamente para a elaboração deste trabalho: Maria Eduarda Francklim, Davi Gomes e Camila Leite. À Petrobras, pela disponibilização dos dados, e aos colegas da equipe de estágio, pelo compartilhamento de conhecimentos que viabilizaram a execução desta pesquisa.

RESUMO

No contexto de expansão das tecnologias de inteligência artificial, a integração entre Geociências e Ciência de Dados revela-se uma estratégia robusta para otimizar processos tradicionalmente manuais na indústria de óleo e gás. No âmbito da avaliação de reservatórios, destaca-se a necessidade do ajuste de profundidade de amostras laterais, inerente ao processo de amostragem em subsuperfície. Atualmente, essa tarefa é realizada de forma manual, podendo consumir horas ou dias para a conclusão de um único poço. Diante desse desafio operacional, o presente trabalho tem como objetivo avaliar o desempenho de um algoritmo desenvolvido pela empresa LTrace, para automatizar esse processo, com ênfase à análise dos erros e sua associação com as características litológicas. Utilizando dados de seis poços do Campo de Sapinhoá, na Bacia de Santos, o fluxo de trabalho compreendeu: o ajuste manual para estabelecimento de uma base de referência (*ground truth*); a execução do ajuste automatizado via modelos R-CNN (*Region-based Convolutional Neural Network*); e a posterior comparação de desempenho por meio de métricas de classificação e regressão. A análise dos resultados foi integrada às características geológicas das formações, revelando que a eficácia do algoritmo é sensível às variações litológicas. Por fim, a realização deste trabalho demonstra que a inteligência artificial se consolida como uma aliada às atividades humanas especializadas, além de provar que a integração de profissionais das Geociências e Ciência de Dados, tem forte potencial para o desenvolvimento e evolução de soluções que compatibilizem a automação de processos e análises a partir do conhecimento do intérprete em geologia.

Palavras-chave: Inteligência artificial; Redes neurais convolucionais; Perfis de imagem acústica; Caracterização de reservatórios.

ABSTRACT

In the context of the rapid expansion of artificial intelligence technologies, the integration of Geosciences and Data Science emerged as a powerful strategy for optimizing traditionally manual workflows in the oil and gas industry. Within reservoir evaluation processes, depth matching of sidewall core samples represents a critical step in subsurface sampling and characterization. Currently, this task is still performed manually and may require several hours or days, to be completed for a single borehole. To address this operational challenge, this study evaluates the performance of an algorithm developed by LTrace Co. to automate the depth-matching task, with emphasis on error analysis and its relationship with lithological characteristics. Using data from six boreholes in the Sapinhoá Field, Santos Basin, the proposed workflow comprised manual depth matching to establish a ground-truth reference, automated matching using Region-based Convolutional Neural Network (R-CNN) models and subsequent performance assessment through classification and regression metrics. The results were integrated with the geological characteristics of the studied formations, demonstrating that algorithm performance is strongly influenced by lithological variability. Overall, the findings indicate that artificial intelligence can serve as a valuable support tool for specialized geological workflows, significantly reducing processing time while maintaining reliable results within a well-defined geological context. The integration between Geology and Data Science demonstrated strong potential for developing solutions that combine process automation with expert geological interpretation, ultimately advancing the efficiency, accuracy and applicability of workflows in the oil and gas industry.

Keywords: Artificial intelligence; Convolutional neural networks; Acoustic image logs; Reservoir characterization.

LISTA DE FIGURAS

Figura 1 - Mapa localização campo de Sapinhoá e Entorno de Sapinhoá.....	21
Figura 2 - Carta estratigráfica do intervalo pré-sal da Bacia de Santos.....	22
Figura 3 - Carta estratigráfica do intervalo pré-sal da Bacia de Santos.....	22
Figura 4 - Discrepância entre profundidade original e real após reajuste.....	24
Figura 5 - Detecção e segmentação em perfis de imagem acústica.....	25
Figura 6 - Fórmulas das métricas de classificação utilizadas.....	27
Figura 7 - Formulação matemática das métricas de erro RMSE e MAE.....	28
Figura 8 – Poço A em função do limiar 0,0125m.....	29
Figura 9 - Proporção de falsos negativos e falsos positivos por litologia.....	32
Figura 10 - Valores reais, estimados, feições geológicas intervalos Poço A..	33
Figura 11 - Proporções de erros por litofácies na Formação Barra Velha.....	38
Figura 12 - Proporções de erros por litofácies na formação Itapema.....	39
Figura 13 - Intervalos representativos das predições falso negativas poço B.	40
Figura 14 - Exemplos de predições falso positivas em imagens acústicas.....	41

LISTA DE TABELAS

Tabela 1 – Síntese das causas de erro de profundidade em operações a cabo	18
Tabela 2 - Desempenho das métricas em função do threshold (Poço A)	31
Tabela 3 - Métricas de desempenho do modelo RCNN1	35
Tabela 4 - Métricas de desempenho do modelo RCNN2	36
Tabela 5 - Comparação de desempenho entre os modelos RCNN1 e RCNN2	37

LISTA DE ABREVIATURAS E SIGLAS

COQ	Coquina
ETR	Estromatólito
GST	Grainstone
HC	Hidrocarbonetos
IA	Inteligência Artificial
MAE	Erro Absoluto Médio (<i>Mean Absolute Error</i>)
MUD	Mudstone
RCNN	Region-based Convolutional Neural Network
RMSE	Raiz do Erro Quadrático Médio (<i>Root Mean Square Error</i>)
RUD	Rudstone
SWC	Amostragem lateral (<i>Sidewall Coring</i>)
TP	Acertos (<i>True Positives</i>)

SUMÁRIO

1 INTRODUÇÃO	12
2 OBJETIVOS	14
3 EMBASAMENTO TEÓRICO.....	15
3.2 Tipos de amostras	16
3.3 Importância das amostras laterais nos estudos geológicos	17
3.4.1 Causas do erro de profundidade em operações a cabo	18
3.5 Aplicações de redes convolucionais nas geociências.....	20
4 CONTEXTO GEOLÓGICO	21
5 MATERIAL E MÉTODOS	23
5.1 Ajuste manual	23
5.2 Ajuste automatizado.....	24
5.3 Métricas de desempenho	26
5.4 Avaliação de desempenho e análise de erros	31
6 RESULTADOS E DISCUSSÕES.....	34
6.1 Modelos RCNN1 e RCNN2	34
6.2 Influência das litofácies	37
6.3 Diagnóstico de erros	39
7 CONCLUSÃO.....	42
REFERÊNCIAS	44

1 INTRODUÇÃO

A aquisição e a interpretação de dados de poço constituem etapas fundamentais na caracterização de reservatórios, especialmente em cenários de elevada complexidade como os campos do Pré-sal. Nesse contexto, o ajuste de profundidade de amostras laterais desempenha um papel central na correlação entre dados laboratoriais e perfis de imagem. Todavia, essa tarefa é tradicionalmente realizada de forma manual, o que a torna suscetível a inconsistências interpretativas e a um elevado consumo de tempo operacional. Embora a aplicação de técnicas de Inteligência Artificial, particularmente modelos de *Deep Learning*, tenha ampliado as possibilidades de automação em geociências, com resultados expressivos na classificação de fácies, o ajuste automatizado de profundidade permanece pouco explorado na literatura, sobretudo no que tange à análise crítica dos erros inerentes aos modelos.

Diante desse cenário, o problema de pesquisa que orienta este trabalho consiste em avaliar a capacidade de arquiteturas de aprendizado profundo em automatizar o ajuste de profundidade e, primordialmente, compreender os fatores geológicos e computacionais que condicionam seus erros. Para tanto, investigou-se o desempenho de um algoritmo baseado em *Region-based Convolutional Neural Networks* (R-CNN), integrando métricas quantitativas a uma rigorosa análise interpretativa. Os achados demonstram que as discrepâncias não se distribuem de forma aleatória, estando diretamente associadas às características litológicas, às condições operacionais do poço e às limitações intrínsecas ao modelo. Assim, ao articular a avaliação de desempenho com o diagnóstico dos erros, este trabalho contribui para um campo ainda incipiente, evidenciando a necessidade de integração entre o conhecimento geológico e o desenvolvimento computacional para o aprimoramento de soluções em ambientes complexos.

Para a viabilização desta pesquisa, utilizou-se um conjunto de dados proveniente de seis poços situados no Campo de Sapinhoá, na porção central da Bacia de Santos, abrangendo seções investigadas das formações Itapema e Barra Velha. A abordagem metodológica fundamentou-se na comparação direta entre o ajuste de profundidade manual, estabelecido como *ground truth*, e o ajuste executado de forma automatizada por meio de modelos R-CNN desenvolvidos pela empresa

LTrace. O fluxo de trabalho compreendeu a aplicação sistemática de métricas estatísticas de classificação e regressão para validar a eficácia do sistema frente à heterogeneidade dos reservatórios carbonáticos analisados.

De forma geral, os resultados obtidos demonstraram elevada exatidão métrica no posicionamento das cavidades, apresentando erros médios absolutos (MAE) em escalas centimétricas, plenamente compatíveis com as margens de tolerância da indústria. Entretanto, a ferramenta revelou desafios significativos na etapa inicial de detecção, na qual o desempenho mostrou-se sensível à presença de texturas heterogêneas e feições naturais que mimetizam as cavidades artificiais. Esse comportamento reforça a importância do diagnóstico litoestratigráfico para o refinamento de modelos de visão computacional.

2 OBJETIVOS

O objetivo central deste trabalho consiste em avaliar o desempenho do algoritmo de *machine learning* desenvolvido para a detecção de cavidades de amostragem lateral, priorizando o diagnóstico detalhado da natureza de seus erros. Esta avaliação de desempenho é fundamental para determinar a viabilidade de inserção da ferramenta na rotina operacional da caracterização de reservatórios. Paralelamente, o diagnóstico das causas determinantes das discrepâncias, sejam elas de origem geológica ou computacional, visa fornecer subsídios técnicos para o aprimoramento contínuo do modelo, assegurando que a inovação tecnológica seja orientada pelo rigor analítico das geociências.

Sob essa ótica, parte-se da premissa de que a consolidação de um desempenho satisfatório, fundamentado em elevadas taxas de acerto nas predições, permitirá a otimização da tarefa de ajuste de profundidade, resultando em um ganho de eficiência produtiva para o geocientista. Em contrapartida, a identificação de eventuais limitações de desempenho atua como um vetor de evolução para a ferramenta; nesse cenário, os dados diagnósticos de inconsistências tornam-se essenciais para orientar o refinamento técnico e as adaptações necessárias ao sistema em etapas subsequentes.

3 EMBASAMENTO TEÓRICO

Para melhor compreensão da problemática abordada neste estudo, o ajuste de profundidade de amostras laterais, é necessário consolidar alguns conhecimentos prévios. Desse modo, este capítulo apresenta os principais métodos de recuperação de amostras em subsuperfície, seus diferentes tipos e características, bem como a importância das amostras laterais nos estudos geológicos. Em seguida, são discutidos os fatores que influenciam os erros de profundidade e os métodos utilizados para seu ajuste, finalizando com uma revisão sobre as aplicações de redes neurais convolucionais em geociências.

3.1 Métodos de amostragem de rochas em subsuperfície

As amostragens são métodos diretos para a aquisição de amostras de rocha ou fluidos em subsuperfície. Na própria coluna de perfuração, são introduzidas ferramentas que recuperaram amostras a mais de 4.000 metros abaixo do assoalho oceânico. Os métodos de amostragem de rocha podem ser classificados em três categorias: amostras de calha, testemunhos e amostras laterais. Cada classe de amostra fornece dados de elevado valor técnico e científico, possibilitando ensaios laboratoriais capazes de revelar propriedades petrofísicas e geoquímicas essenciais à caracterização dos intervalos portadores de petróleo.

A caracterização de reservatórios é significativamente enriquecida pelas amostras recuperadas do interior do poço. Este processo corresponde à fase em que se integram dados geofísicos (sísmica, perfis de poço) com informações diretas de amostragem para descrever, com o maior detalhamento possível, a geometria, a litologia e as propriedades petrofísicas de uma acumulação de hidrocarbonetos (HC). Nessa etapa, amostras de calha, testemunhos e, sobretudo, amostras laterais fornecem material essencial para ensaios petrofísicos (e.g., porosidade, permeabilidade, saturação de fluidos e resistividade), parâmetros que não podem ser inferidos com igual confiabilidade apenas por métodos indiretos. A correta aquisição e o adequado posicionamento em profundidade desses corpos de prova são, portanto, decisivos para construir modelos de reservatório robustos, estimar volumes recuperáveis e orientar estratégias de desenvolvimento e produção com menor incerteza.

3.2 Tipos de amostras

Cada uma das três categorias de amostragem de rocha em subsuperfície, possui sua maneira de ser recuperada e permite obter diferentes informações. Amostras de calha (*cutting*) são fragmentos de rocha resultantes da ação trituratora de brocas, que são transportadas juntamente com o fluido de perfuração até a peneira da sonda. Permitem identificar o tipo de rocha, composição mineralógica básica, granulometria, seleção e arredondamento de grãos e indícios de HC.

Os testemunhos de sondagem (*core*) são cilindros de rocha maciça extraídos do poço por meio de ferramenta especial, composta por uma broca com coroa diamantada que corta um núcleo intacto da formação e o armazena em um porta-amostras denominado barrilete. Esses testemunhos apresentam, em geral, diâmetros entre aproximadamente 2,5 e 4 polegadas (cerca de 6,3 a 10 cm), podendo atingir comprimentos de vários metros por corrida, a depender das condições operacionais e do intervalo amostrado. Essa dimensão contínua e representativa permite a identificação detalhada de características físicas, mineralogia e feições estruturais e sedimentológicas da rocha. Apesar de ser um procedimento mais demorado e oneroso financeiramente, permite um detalhamento fundamental das formações atravessadas, especialmente a medição confiável de propriedades da rocha.

Por fim, temos as amostras laterais de rocha (*sidewall core*), que são plugues cilíndricos coletados diretamente da parede do poço por ferramentas rotativas ou percussivas durante a perfilagem. Elas diferem da testemunhagem por serem pontuais, e não contínuas. Os plugues, que têm diâmetros de 1 a 1,5 polegadas e 1,5 a 1,75 polegadas de comprimento, podem representar a coluna de rocha de uma dada formação e permitem avaliar características diversas, como feições deposicionais e diagenéticas, presença de HC e propriedades petrofísicas.

A recuperação de amostras laterais pode ser conduzida de duas maneiras: amostragem percussiva ou amostragem rotativa. Ambas são conduzidas a poço aberto, ou seja, a ferramenta é descida por cabo (*wireline*) até a profundidade pré-estabelecida e faz contato direto com a formação, uma vez que ainda não foi dado início ao revestimento e à cimentação.

Em seu trabalho, "*A Review of Sidewall Coring Practice*", o autor Webster (1959) menciona que a técnica de amostragem lateral percussiva, precursora da técnica rotativa, já era aplicada antes da década de 1960. No método percussivo, a

recuperação da amostra de rocha é realizada a partir do disparo de um projétil oco contra a formação. Porém, algumas desvantagens fazem parte deste método, como dano à rocha e alteração de propriedades físicas, como porosidade e permeabilidade.

A amostragem lateral rotativa é uma técnica que recupera o corpo de prova por meio de uma ferramenta de corte, que extrai um cilindro de rocha diretamente na parede do poço. O material é retirado em sentido perpendicular ao eixo do poço e, em seguida, é acondicionado em um barrilete, preservando a ordem de coleta e sua respectiva profundidade. Concluída a operação, a ferramenta é deslocada para a próxima profundidade de interesse, repetindo-se o ciclo até o término do programa de amostragem.

As amostras laterais abordadas no presente estudo foram obtidas por meio da técnica de amostragem lateral rotativa. Embora o método rotativo seja operacionalmente mais complexo que o percussivo, sua adoção tem sido crescente por garantir uma integridade superior do corpo de prova. Além disso, a amostragem lateral (*sidewall coring*) é mais econômica em relação a testemunhagem convencional e permite recuperar amostras pontualmente do local de interesse.

3.3 Importância das amostras laterais nos estudos geológicos

A amostragem lateral (*Sidewall Coring* – SWC) se destaca por sua alta seletividade amostral e a eficiência temporal, além da redução significativa de custos e da logística operacional. O planejamento da seleção das profundidades de recuperação dos testemunhos laterais é fundamental, pois a coleta é pontual e ocorre na exata profundidade previamente programada. Portanto, essa precisão possibilita a amostragem focada em diversas litologias cruciais, como a rocha-reservatório, a rocha-capeadora e a rocha-geradora. Adicionalmente, a maior eficiência temporal da SWC está diretamente ligada à otimização do tempo de sonda (*rig time*). Esta operação, realizada via *wireline*, elimina a necessidade de manobras de retirada e substituição da coluna de perfuração e permite coletar mais de 30 amostras por descida (ROURKE; TORNE, 2011; TORLOV *et al.*, 2018).

As amostras laterais desempenham um papel central na correlação rocha-perfil, uma vez que o seu registro de recuperação constitui a base fundamental para o ajuste de profundidade. Para que a caracterização do reservatório seja concluída com sucesso, é imperativo o alinhamento preciso entre os dados laboratoriais e cada um dos perfis petrofísicos registrados. Além do mais, possui auxílio do perfil de raios

gama (*gamma ray*), por ser realizado de forma integrada em todas as corridas de perfilagem, serve como o referencial comum que permite correlacionar as diferentes escalas de medição e garantir a consistência espacial dos dados geológicos.

3.4 Ajuste de profundidade de amostras laterais

O ajuste de profundidade consolida-se como uma etapa obrigatória para garantir a integridade da correlação rocha-perfil e consequentemente a avaliação de formação, visando compreender o reservatório e maximizar sua produtividade. Em intervalos de rochas laminadas, nos quais a resolução vertical dos perfis de imagem é determinante para a interpretação geológica, qualquer pequeno deslocamento pode impedir que as amostras laterais correspondam fielmente às cavidades identificadas nos perfis de imagem. Sendo assim, o posicionamento fiel das amostras é frequentemente prejudicado por fatores intrínsecos ao processo de aquisição.

3.4.1 causas do erro de profundidade em operações a cabo

As causas primordiais dos erros de profundidade, sintetizadas na Tabela 1, foram abordadas por Fitzgerald, 2008. Referem-se ao momento (*momentum*) da ferramenta, à elasticidade do cabo, à viscosidade do fluido, ao efeito *stick-slip* e às heterogeneidades (ex: rugosidade, desmoronamento de parede) e são variáveis inerentes às operações de amostragem a cabo em poço aberto.

Tabela 1 - Síntese das causas de erro de profundidade em operações a cabo

Causa do Erro	Mecanismo Físico	Impacto na Profundidade
Momento (<i>momentum</i>)	Inércia da massa da ferramenta durante aceleração ou frenagem.	Descompasso entre a leitura do odômetro e a posição real da ferramenta.
Elasticidade do Cabo	Estiramento elástico variável em função do peso e da profundidade.	Atraso (<i>delay</i>) na resposta da ferramenta; erro de posicionamento em poços profundos.
Viscosidade do Fluido	Resistência hidrodinâmica (arrasto) sobre o cabo e a ferramenta.	Alteração na tensão do cabo e redução da velocidade de descida efetiva.
Efeito <i>Stick-Slip</i>	Ciclos de travamento e liberação devido ao atrito com a parede do poço.	Movimento intermitente (picos e solavancos), gerando registro de profundidade impreciso.
Heterogeneidades	Rugosidades, <i>wash-outs</i> e acúmulo de reboco (<i>mud cake</i>).	Instabilidade mecânica da trajetória e distúrbios físicos no deslocamento.

Fonte: Adaptado de Fitzgerald (2008).

Fatores dinâmicos contribuem para a imprecisão da profundidade, como o momento (*momentum*), que está relacionado à inércia da massa da ferramenta, acelerações ou frenagens bruscas. Adicionalmente, a elasticidade do cabo e a viscosidade do fluido, atuam simultaneamente sob o peso da ferramenta e a extensão da coluna de fluido. O cabo sofre um estiramento elástico variável que se intensifica com a profundidade, causando um atraso (*delay*) na resposta da ferramenta aos comandos de superfície, em decorrência da resistência hidrodinâmica (arrasto) exercida pelo fluido de perfuração.

Por fim, o ambiente de poço aberto pode apresentar heterogeneidades secundárias que comprometem a uniformidade da trajetória, tais como rugosidades excessivas e alargamentos do poço (*wash-outs*). Essas irregularidades atuam como obstáculos físicos, gerando variações bruscas no atrito entre a ferramenta e a parede da formação, impedindo que o cabo se desloque de maneira constante e previsível. Portanto, a variação de atrito desencadeia o fenômeno mecânico conhecido como *stick-slip*, no qual a ferramenta trava momentaneamente e libera-se em seguida de forma abrupta. O somatório desses fatores exige correções contínuas, pois gera divergências entre a profundidade medida pela rotação da polia contadora e a posição real da ferramenta no fundo do poço, além de registro de imagens com aspecto desfocado (*blurring*).

3.4.2 Métodos de ajuste de profundidade

Tradicionalmente, a discrepância entre profundidade do cabo e a profundidade real do amostrador é ajustada integralmente de forma manual. O processo utiliza como referência a localização das cavidades deixadas nos perfis de imagem acústica pela coleta dos corpos de prova e os registros da profundidade do sondador. O intérprete realoca cada profundidade registrada pelo cabo até que ela coincida com a cavidade visível correspondente à extração da amostra. Este valor reajustado passa a ser considerado a profundidade real da amostra lateral. Dado que um único poço pode conter de dezenas a centenas de amostras, esse procedimento manual é demorado e sujeito a erros.

Diante disto, e da atual conjuntura tecnológica, a popularização da inteligência artificial (IA) confere um forte valor ao conhecimento e à capacidade analítica e operacional de geocientistas. Isto se opõe à ideia da automação como elemento de substituição do profissional por métodos de aprendizado de máquina. A tecnologia

atua como uma aliada estratégica, facilitando, acelerando, automatizando e aprimorando a execução de tarefas. O presente trabalho representa a primeira fase de desenvolvimento de uma rotina desenvolvida a partir da integração entre geocientistas e engenheiros de *software*, derivada de uma colaboração entre a indústria e a academia. Isto resultou em um protótipo de sistema computacional da empresa LTrace, que tem como objetivo utilizar o aprendizado de máquina para ajustar de forma automatizada as amostras laterais, reduzindo o tempo de execução de ajuste de dias para minutos e os erros de posicionamento.

3.5 Aplicações de redes convolucionais nas geociências

O *Deep Learning*, subcampo do Aprendizado de Máquina, fundamenta-se em arquiteturas de redes neurais artificiais com múltiplas camadas de processamento, voltadas à extração automática de padrões complexos (LECUN; BENGIO; HINTON, 2015). No contexto geológico, a interpretação baseia-se majoritariamente em imagens, sejam elas fotográficas, microscópicas ou geofísicas, o que torna as Redes Neurais Convolucionais (CNNs) particularmente adequadas para esse tipo de análise. Estas redes utilizam operações de convolução para extrair características espaciais relevantes, como texturas e formas, sem a necessidade de definição manual de atributos (KRIZHEVSKY *et al.*, 2017). Modelos mais avançados, como as R-CNNs, ampliam essa capacidade ao integrar detecção e segmentação de objetos, permitindo a identificação precisa de feições em domínios visuais complexos.

Visto que a geologia é uma ciência essencialmente visual e multiescala, a aplicação das redes profundas para aprender representações complexas tem apresentado resultados satisfatórios (FIORITI; GOUVÊA; CARNEIRO, 2025). Na escala regional, a interpretação de volumes de dados sísmicos beneficia-se da detecção automática de feições estruturais. Tian *et al.* (2025) exploraram o uso de *deep learning* para a classificação de fácies sísmicas, acelerando o mapeamento de sistemas deposicionais em bacias sedimentares de grande extensão. Na escala de afloramento, Roemers-Oliveira *et al.* (2025) aplicam visão computacional para o mapeamento automatizado de fácies em afloramentos, demonstrando como a segmentação inteligente pode agilizar a caracterização de corpos sedimentares complexos. Por fim, na escala microscópica, o trabalho de BICUDO *et al.* (2025) aplica *machine learning* para extrair porosidade e conectividade a partir de fotomicrografias.

4 CONTEXTO GEOLÓGICO

A Bacia de Santos, localizada na margem leste brasileira, é uma bacia *offshore* de margem passiva com 350 mil km², formada pelo rifteamento do Gondwana e a consequente abertura do Atlântico Sul (MOULIN *et al.*, 2010). Nesse cenário, a província do Pré-sal apresenta reservatórios carbonáticos complexos, como o Campo de Sapinhoá, escolhido para este estudo devido ao expressivo volume de dados e informações técnicas publicamente disponíveis (BELILA *et al.*, 2022; MOHRIAK *et al.*, 2008; GOMES *et al.*, 2020). O Campo de Sapinhoá situa-se em um ambiente de águas ultra profundas, sob uma lâmina d'água de aproximadamente 2.140 metros, estando geograficamente posicionado a cerca de 310 km da costa, a 360 km da cidade de São Paulo e 290 km da cidade do Rio de Janeiro (Figura 1), na porção central da Bacia de Santos.




Figura 1 - Mapa localização campo de Sapinhoá e Entorno de Sapinhoá.
Fonte: ANP (2025).

Embora o arcabouço estratigráfico da Bacia de Santos tenha sido amplamente detalhado por Moreira *et al.* (2007) em sua totalidade, o presente estudo concentra-se em uma seção específica do campo de Sapinhoá, compreendendo as formações Itapema e Barra Velha (Figura 2). A Formação Itapema, associada ao estágio de *upper rift*, caracteriza-se por intercalações de calcirruditos compostos por fragmentos

bioclásticos (coquinas) que, em porções mais distais, alternam-se com folhelhos negrosícos em matéria orgânica. Sobrejacente a esta unidade, a Formação Barra Velha, representante da fase sag/pós-rifte, é predominantemente composta por rochas carbonáticas diversas, incluindo estromatólitos, laminitos em regiões proximais, além de folhelhos em áreas distais. Adicionalmente, identificaram-se níveis de *grainstones* e *packstones* constituídos por detritos de microbialitos e bioclastos, como ostracodes, evidenciando a complexidade deposicional deste intervalo (MOREIRA et al., 2007). Dada a complexidade textural e a heterogeneidade porosa das Formações Itapema e Barra Velha, devido à sua diversidade litológica resultante da combinação de processos deposicionais e diagenéticos de natureza química e hidrotermal (BELILA et al., 2022), a identificação visual de cavidades torna-se um desafio interpretativo. Nesse cenário, as Redes Neurais Convolucionais (CNNs) surgem como a arquitetura ideal, uma vez que sua capacidade de extrair atributos espaciais e gradientes lito estratigráficos permite processar a complexidade dessas imagens acústicas com um rigor matemático superior aos métodos lineares tradicionais.




Figura 2 - Carta estratigráfica do intervalo pré-sal da Bacia de Santos
Fonte: Adaptado de MOREIRA et al., 2007.



Figura 3 - Carta estratigráfica do intervalo pré-sal da Bacia de Santos
Fonte: Adaptado de MOREIRA et al., 2007.

5 MATERIAL E MÉTODOS


A seleção do conjunto amostral decorreu da expressiva densidade de dados disponíveis, fator determinante para mitigar riscos de inconsistências decorrentes de escassez informativa. Cada poço apresenta uma seção investigada de aproximadamente 1.000 metros, situada em um intervalo entre 5.000 e 6.000 metros de profundidade em subsuperfície.

O fluxo metodológico deste trabalho compreendeu três etapas fundamentais. Inicialmente, realizou-se o ajuste manual no *software* Geolog (Aspentech), integrando perfis de imagem acústica, profundidades nominais de recuperação das amostras laterais e, complementarmente, dados de descrição macroscópica e microscópica. Subsequentemente, procedeu-se ao ajuste automatizado por meio da ferramenta *Instance Segmenter* (LTrace), operada no módulo *Well Log* do *software* GeoSlicer. Por fim, o desempenho da ferramenta na identificação de cavidades de amostragem foi mensurado através de métricas de classificação (revocação e precisão) e de regressão (Erro Médio Absoluto e Raiz do Erro Quadrático Médio), com foco na análise diagnóstica das causas de erro.

5.1 Ajuste manual

Inicialmente, as profundidades nominais de amostragem e os perfis de imagem acústica foram importados para o *software* Geolog (Aspentech). É notório a discrepância entre as profundidades registradas pelo sondador e as cavidades correspondentes nos perfis de imagem. É diante desta inconsistência que se faz necessário o ajuste das profundidades, utilizando as cavidades identificadas como registros efetivos de recuperação de amostra lateral como referência. Este procedimento de reajuste foi aplicado de forma sistemática em todos os seis poços (Figura 3).

a)



b)




Figura 4 - Discrepância entre profundidade original e real após reajuste.

a) Perfil de imagem acústica (amplitude) à esquerda, com registros de amostragem lateral destacados em quadrados amarelos. À direita, representação da profundidade original por pontos pretos. b) Setas azuis indicam ajuste manual, onde pontos vermelhos representam a profundidade real, alinhadas com as cavidades do perfil de imagem.

Fonte: Adaptado do *software* Geolog.

5.2 Ajuste automatizado

Utilizando o algoritmo *Mask R-CNN* (MATTERPORT, 2017), a equipe da LTrace implementou uma abordagem de segmentação por instâncias treinada por meio de aprendizado supervisionado. Para isso, a rede foi alimentada com uma base de dados rotulada contendo perfis de imagem acústica do Pré-Sal. Uma vez que a

CNN mapeia e reconhece os padrões desse conjunto de treinamento, ela adquire a capacidade de realizar detecções de forma autônoma. Esse método permite flexibilidade ao modelo para padrões visuais, capacitando-o a diferenciar cavidades de recuperação de amostra lateral de características litológicas e ruídos, induzindo a diminuição de detecções falso positivas.

O algoritmo foi treinado com dois modelos diferentes, RCNN1 e RCNN2, tendo como objetivo detectar e segmentar os registros da recuperação de amostras laterais em imagens acústicas. Para além disso, a rede também foi treinada para criar uma máscara individual para cada registro de amostra lateral detectada. Portanto, o treinamento da *Mask R-CNN* utilizou o modelo de segmentação em instâncias de dois estágios, onde ocorre detecção e segmentação simultaneamente, tendo cada amostra contornada por seu formato (Figura 4). A automatização foi executada poço a poço, cada um deles recebendo aplicação tanto do modelo RCNN1 quanto do RCNN2.




Figura 5 - Detecção e segmentação em perfis de imagem acústica. À esquerda cavidades de amostras laterais. À direita cavidades identificadas e segmentadas pelo algoritmo.
Fonte: Adaptado do *software* Geoslicer.

5.3 Métricas de desempenho

A metodologia de avaliação de desempenho foi estruturada a partir da aplicação sequencial de métricas de classificação e de regressão, adotando-se o isolamento dessas análises para garantir a coerência da análise, uma vez que, sem um desempenho satisfatório em identificar corretamente as cavidades, a análise do ajuste de profundidade careceria de fundamento estatístico. Para obter uma análise otimizada, a aplicação das métricas foi conduzida via *script* em linguagem Python, processando os dados individualmente, poço a poço.

Nesse sentido, para a aplicação das métricas de classificação, adotou-se a listagem de profundidades ajustadas manualmente como *ground truth* (verdade de campo) em relação às profundidades preditas pelo algoritmo. A partir dessa referência, quantificaram-se os Falsos Positivos (FP), Falsos Negativos (FN) e Verdadeiros Positivos (VP) para cada poço, viabilizando o cálculo das métricas de Precisão e Revocação (Figura 5A e Figura 5B). Enquanto a Precisão (*precision*) indica a assertividade do modelo na identificação fidedigna das cavidades, a Revocação (*recall*) reflete a sensibilidade do sistema em detectar a totalidade das amostras presentes no perfil. A síntese desse desempenho é expressa pelo *F1-score*, o qual, por meio da média harmônica entre as métricas anteriores, penaliza eventuais desequilíbrios entre alarmes falsos e omissões (Figura 5C). Dessa maneira, a obtenção de um elevado valor de *F1-score* consolida a eficácia do modelo na identificação das amostras, validando a robustez da ferramenta no contexto operacional da caracterização de reservatórios.




Figura 6 - Fórmulas das métricas de classificação utilizadas
 VP representa os Verdadeiros Positivos, FP os falsos Positivos e FN os falsos negativos.
 Fonte: Elaboração própria.


Concluída a etapa de classificação, procedeu-se à aplicação das métricas de regressão para mensurar a exatidão posicional do ajuste de profundidade. Para tanto, selecionaram-se o Erro Médio Absoluto (*Mean Absolute Error* – MAE) e a Raiz do Erro Quadrático Médio (*Root Mean Square Error* – RMSE), indicadores que quantificam a magnitude da discrepância entre as profundidades preditas pelo algoritmo e os valores de referência do *ground truth* (FIGURA 6 - Fórmulas das métricas de regressão para avaliação do ajuste de profundidade). Enquanto o MAE fornece uma medida direta do distanciamento absoluto médio das amostras, o RMSE atua como um indicador sensível à presença de *outliers*. Complementarmente, o gráfico de resíduos e a análise do Erro Máximo permitem identificar os desvios mais acentuados, fornecendo uma visão clara da confiabilidade métrica do sistema (Figura 7).

$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ RMSE: raiz do erro quadrático médio. Penaliza erros maiores de forma mais severa.	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $ MAE: erro absoluto médio. Representa o erro médio absoluto entre os valores observados e previstos.
---	---

- n : número total de amostras analisadas;
- y_i : profundidade real da amostra i (*ground truth*);
- $\hat{y}_i$: profundidade predita pelo algoritmo para a amostra i ;
- $|y_i - \hat{y}_i|$: resíduo ou erro absoluto da predição.

Figura 7 - Formulação matemática das métricas de erro RMSE e MAE.
Fonte: Elaboração própria.

a)



b)




Figura 8 – Poço A em função do limiar 0,0125m

a) Distribuição dos resíduos em função da profundidade. b) Evolução das métricas de erro (MAE, RMSE e erro máximo).

Fonte: Elaboração própria.

Para validar o desempenho nesta etapa, estabeleceu-se um *threshold* de 0,125m, definido a partir de testes sucessivos com diferentes valores desse parâmetro, com o objetivo de avaliar a sensibilidade das métricas de desempenho frente à variação do critério de aceitação, conforme apresentado na Tabela 2. Nesse contexto, sempre que a distância absoluta entre a amostra real e a predita ultrapassa esse limite, a detecção é reclassificada como um falso positivo.

Tabela 2 - Desempenho das métricas em função do threshold (Poço A)

Threshold (m)	TP (acertos)	MAE (m)	RMSE (m)	Erro Máximo (m)
0,050	8	0,03	0,03	0,05
0,075	10	0,04	0,04	0,07
0,100	16	0,06	0,06	0,10
0,125	21	0,07	0,08	0,11
0,150	29	0,09	0,10	0,15
0,175	36	0,10	0,11	0,17
0,200	37	0,10	0,11	0,18
0,225	40	0,11	0,12	0,22
0,250	41	0,11	0,13	0,23

Fonte: Elaboração própria

A análise dos resultados evidencia que o aumento progressivo do *threshold* está diretamente associado ao crescimento do número de acertos (TP), que passa de 8 para 41 ao longo do intervalo testado, indicando maior tolerância na correspondência entre valores reais e preditos. Em contrapartida, observa-se elevação contínua das métricas de erro, com o MAE variando de 0,0287 m para 0,1134 m e o RMSE de 0,0306 m para 0,1269 m, refletindo o aumento da

permissividade na aceitação de desvios posicionais. O erro máximo acompanha essa tendência, ampliando-se conforme o limite adotado.

Observa-se que, a partir de aproximadamente 0,150m, o incremento no número de acertos torna-se menos expressivo, especialmente quando comparado ao crescimento contínuo das métricas de erro. Esse comportamento indica a transição para um regime de ganhos marginais, no qual o aumento do *threshold* resulta em melhoria limitada na capacidade de detecção, ao passo que amplia significativamente a magnitude dos erros aceitos. Nesse contexto, a adoção do valor de 0,125 m configura-se como uma escolha conservadora, posicionada imediatamente antes dessa região, permitindo equilibrar o ganho em detecção com o controle dos desvios, preservando maior rigor na qualidade do ajuste sem comprometer de forma significativa o desempenho do modelo.

5.4 Avaliação de desempenho e análise de erros

A avaliação de desempenho foi estruturada a partir de uma abordagem quantitativa e interpretativa, visando compreender o desempenho dos modelos e identificar padrões de erro. Considerando a natureza heterogênea dos dados, distribuídos entre diferentes poços com características geológicas distintas, adotou-se como critério principal de comparação o método de agregação denominado *macro-average*, no qual as métricas são inicialmente calculadas de forma independente para cada poço e, posteriormente, promediadas com atribuição de peso igual. Essa abordagem permite avaliar a consistência e a capacidade de generalização espacial dos modelos, evitando que poços com maior número de amostras exerçam influência desproporcional sobre os resultados globais.

Adicionalmente, foi calculado o *micro-average*, por meio da quantificação proporcional dos Falsos Positivos (FP) e Falsos Negativos (FN) em cada litofácies permitindo uma análise mais detalhada da distribuição dos erros em função das características geológicas (Figura 8). Com o intuito de refinar a interpretação dos resultados e respeitar as particularidades litoestratigráficas, os dados foram organizados de acordo com as formações atravessadas pelos poços, sendo a distribuição dos erros analisada de forma independente para as formações Barra Velha e Itapema. Essa abordagem possibilitou a geração de gráficos de composição percentual, evidenciando a contribuição relativa de cada litologia nas ocorrências de

erro e fornecendo uma visão clara dos intervalos geológicos mais desafiadores para o modelo.

$\text{Proporção de } FN_L = \left(\frac{FN \text{ na litologia } L}{\text{Total de } FN \text{ na Formação}} \right) \times 100$
$\text{Proporção de } FP_L = \left(\frac{FP \text{ na litologia } L}{\text{Total de } FP \text{ na Formação}} \right) \times 100$

Onde:

FN_L = número de falsos negativos na litologia L

FP_L = número de falsos positivos na litologia L

L = litologia analisada

Formação = unidade estratigráfica à qual a litologia pertence

Figura 9 - Proporção de falsos negativos e falsos positivos por litologia.

Fonte: Elaboração própria

Para o diagnóstico dos erros, os resultados quantitativos foram integrados à análise visual dos perfis de imagem acústica, permitindo a espacialização das detecções ao longo da profundidade e a verificação direta das ocorrências de falsos positivos e falsos negativos. Com o suporte computacional da linguagem Python, foi elaborado, para cada poço, diagramas de correlação entre os valores reais e preditos, os quais foram incorporados à análise dos perfis de imagem (Figura 9).

Essa integração possibilitou correlacionar as predições do modelo com as feições observadas nos registros, assegurando maior consistência na identificação das discrepâncias e na localização precisa dos eventos analisados. Dessa forma, o instrumental estatístico adotado permitiu não apenas uma visualização panorâmica da distribuição dos erros, mas também a articulação direta entre as métricas de desempenho e o contexto geológico, constituindo o arcabouço analítico necessário para o diagnóstico lito estratigráfico das discrepâncias do modelo.




Figura 10 - Valores reais, estimados, feições geológicas intervalos Poço A.
 A) Comparação entre as profundidades reais e preditas ao longo do Poço A, com indicação de intervalos seleccionados, de B a F, para análise detalhada. B, C, D, E e F) Perfis de imagem acústica de seus respectivos intervalos.

Fonte: Adaptado do *software* Geolog.

6 RESULTADOS E DISCUSSÕES

Com base na abordagem quantitativa e interpretativa adotada na avaliação de desempenho, este capítulo apresenta os resultados obtidos a partir do fluxo de validação da automação do ajuste de profundidade de amostras laterais, bem como o diagnóstico dos erros associados. A análise está estruturada na integração entre o desempenho algorítmico, mensurado por métricas de exatidão, precisão e revocação, e a realidade litoestratigráfica observada nas Formações Itapema e Barra Velha. Por meio de uma abordagem comparativa, busca-se não apenas quantificar o erro residual do modelo, mas também interpretar os fatores geológicos e operacionais que condicionam a eficácia da ferramenta nos intervalos analisados.

6.1 Modelos RCNN1 e RCNN2

A análise comparativa entre os modelos RCNN1 e RCNN2, fundamentada na abordagem *macro-average*, evidencia diferenças consistentes de desempenho ao longo dos poços analisados (Tabela 3 e Tabela 4). De modo geral, o RCNN1 apresenta maior capacidade de detecção, refletida em valores superiores de precisão, revocação e F1-score, enquanto o RCNN2 adota um comportamento mais conservador, caracterizado pela redução sistemática no número total de predições.

Tabela 3 - Métricas de desempenho do modelo RCNN1

RCNN1											
Poço	Nº Reais	Nº Preditos	TP	FP	FN	Precisão	Revocação	F1-score	MAE (m)	RMSE (m)	Erro Máx (m)
Poço A	212	482	161	321	51	33,4%	75,9%	46,4%	0,032	0,042	0,122
Poço B	146	53	22	31	124	41,5%	15,1%	22,1%	0,030	0,034	0,080
Poço C	44	68	32	36	12	47,1%	72,7%	57,1%	0,042	0,048	0,090
Poço D	132	153	82	71	50	53,6%	62,1%	57,5%	0,022	0,024	0,050
Poço E	153	197	98	99	55	49,7%	64,1%	56,0%	0,023	0,025	0,064
Poço F	73	104	47	57	26	45,2%	64,4%	53,1%	0,024	0,025	0,045
Macro-Wave						45,0%	59,1%	48,7%	0,029	0,033	0,075

Fonte: Elaboração própria

Tabela 4 - Métricas de desempenho do modelo RCNN2

RCNN2											
Poço	Nº Reais	Nº Preditos	TP	FP	FN	Precisão	Revocação	F1-score	MAE (m)	RMSE (m)	Erro Máx (m)
Poço A	212	313	93	220	119	29,7%	43,9%	35,4%	0,040	0,051	0,122
Poço B	146	41	16	25	130	39,0%	11,0%	17,1%	0,030	0,035	0,071
Poço C	44	49	23	26	21	46,9%	52,3%	49,5%	0,040	0,046	0,080
Poço D	132	111	62	49	70	55,9%	47,0%	51,0%	0,022	0,024	0,050
Poço E	153	167	90	77	63	53,9%	58,8%	56,2%	0,023	0,025	0,064
Poço F	73	112	28	84	45	25,0%	38,4%	30,3%	0,026	0,030	0,089
Macro-wave						41,7%	41,9%	39,9%	0,03	0,035	0,079

Fonte: Elaboração própria

A avaliação por poço revela padrões importantes na relação entre valores reais e preditos. Nos Poços A, C e E, observa-se superestimação das detecções em ambos os modelos; entretanto, no RCNN2, essa diferença é reduzida em relação ao RCNN1, indicando diminuição dos falsos positivos. Em contrapartida, no Poço F, essa relação se mostra menos uniforme, com aumento da discrepância entre valores reais e preditos. Já o Poço D apresenta comportamento mais equilibrado, especialmente no RCNN2, no qual o número de amostras preditas se aproxima do valor real, indicando melhor ajuste local do modelo. Por outro lado, o Poço B mantém comportamento distinto, com número de predições substancialmente inferior ao de amostras reais em ambos os modelos, evidenciando elevada ocorrência de falsos negativos e baixa sensibilidade.

Ao estabelecer um paralelo entre os modelos, observa-se que a redução das predições no RCNN2 resulta em diminuição dos falsos positivos, porém acompanhada de aumento expressivo dos falsos negativos, indicando perda de sensibilidade. Esse comportamento é particularmente evidente no Poço A, onde a redução dos falsos positivos (de 321 para 220) ocorre simultaneamente ao aumento significativo dos falsos negativos (de 51 para 119), impactando diretamente a revocação. Tendência semelhante é observada nos Poços C e E, enquanto no Poço F essa relação se apresenta de forma menos consistente.

Em termos globais, considerando os valores de *macro-average*, o RCNN1 apresenta desempenho superior nas métricas de classificação, com maior precisão

(45,0% vs. 41,7%), revocação (59,1% vs. 41,9%) e F1-score (48,7% vs. 39,9%), indicando melhor equilíbrio entre a capacidade de detecção e o controle de falsos positivos (Tabela 5). A diferença mais expressiva ocorre na revocação ($\Delta \approx -17\%$), evidenciando aumento significativo de falsos negativos no RCNN2. Esse comportamento também se reflete na análise *micro-average*, indicando que a redução de desempenho não está restrita a poços específicos, mas distribuída de forma consistente no conjunto analisado.

Tabela 5 - Comparação de desempenho entre os modelos RCNN1 e RCNN2

Métricas	Média RCNN1	Média RCNN2	Variação Δ
Precisão	45,1%	41,7%	▼ -3,35%
Revocação	59,1%	41,9%	▼ -17,15%
F1-Score	48,7%	39,9%	▼ -8,78
MAE	0,029 m	0,030 m	▲ +1,0 mm (Pior)
RMSE	0,033 m	0,035 m	▲ +2,0 mm (Pior)

Fonte: Elaboração própria

Considerando o desempenho superior do RCNN1, as análises subsequentes concentram-se neste modelo. Observa-se melhor desempenho nos Poços C, D e E, nos quais os valores de revocação e F1-score são mais elevados, indicando maior equilíbrio entre sensibilidade e controle de falsos positivos. Em contraste, o Poço B apresenta desempenho significativamente inferior, com baixa revocação e predominância de falsos negativos, evidenciando limitações do modelo em contextos geológicos mais complexos. De modo geral, os valores de precisão e revocação situam-se em níveis moderados, resultando em F1-scores inferiores a 60% em todos dos casos, o que indica a persistência de erros relevantes na etapa de detecção. Esses resultados apontam para limitações na capacidade de generalização do modelo frente à variabilidade dos dados, especialmente em ambientes caracterizados por elevada heterogeneidade textural.

Por outro lado, as métricas de regressão indicam elevado desempenho no ajuste de profundidade das cavidades corretamente identificadas. Os valores reduzidos de MAE e RMSE (médias de aproximadamente 0,029 m e 0,033 m,

respectivamente) demonstram que, uma vez reconhecida a cavidade, o modelo apresenta elevada precisão no posicionamento, com erros compatíveis com aplicações operacionais. Esse contraste evidencia que a principal limitação do modelo reside na etapa de detecção, e não na acurácia geométrica do ajuste, reforçando a necessidade de aprimoramento na identificação das cavidades para aumento da confiabilidade global do sistema.

6.2 Influência das litofácies

A análise *micro-average*, baseada na distribuição dos erros por litologia, permite aprofundar a compreensão dos fatores que condicionam o desempenho do modelo, evidenciando a influência direta das características geológicas na ocorrência de erros. Na Formação Barra Velha, os erros do modelo concentram-se principalmente nos estromatólitos (ETR), que representam o principal desafio à detecção das cavidades. Esses intervalos concentram simultaneamente elevadas proporções de falsos positivos (47,40%) e falsos negativos (33,50%), evidenciando a dificuldade do algoritmo em discriminar feições naturais da rocha das cavidades de amostragem lateral. Tal comportamento está associado à elevada porosidade do tipo *framework*, à rugosidade e às estruturas laminadas características dessas rochas, que, nos perfis de imagem acústica, geram padrões visuais semelhantes às cavidades. Adicionalmente, litologias como esferulitos (ESF) e grainstones (GST) também contribuem para os erros, especialmente na forma de omissões, refletindo a complexidade textural e a heterogeneidade interna desses intervalos, que reduzem o contraste necessário à segmentação (Figura 10).

Formação Barra Velha




Figura 11 - Proporções de erros por litofácies na Formação Barra Velha
 ETR=estromatólito; ESF=esferulito; GST=grainstone; LMT=laminito; RUD=rudito; COQ =coquina;
 MUD=mudstone
 Fonte: Elaboração própria

Na Formação Itapema, o padrão de erro é marcado por contrastes litológicos distintos, nos quais os mudstones (MUD) se destacam como principal fonte de falsos positivos, concentrando 52,90% dessas ocorrências. Esse comportamento está associado à granulometria fina dessas rochas, que favorece a formação de instabilidades na parede do poço, como *breakouts*, frequentemente interpretadas pelo modelo como cavidades. Em contrapartida, as coquinas (COQ) concentram 40% dos falsos negativos, evidenciando a dificuldade do algoritmo em identificar cavidades em ambientes de elevada heterogeneidade textural, nos quais o contraste acústico é parcialmente mascarado pela própria estrutura da rocha (Figura 11).




Figura 12 - Proporções de erros por litofácies na formação Itapema

MUD=mudstone; COQ =coquina; LMT=laminito; ETR=estromatólito; GST=grainstone; ESF=esferulito; RUD=rudito

Fonte: Elaboração própria.

Esses resultados evidenciam que os falsos positivos estão majoritariamente associados a litologias cujas feições naturais mimetizam cavidades, enquanto os falsos negativos concentram-se em litologias cuja heterogeneidade reduz o contraste necessário à detecção. Dessa forma, a variabilidade litofaciológica constitui um fator determinante na performance do modelo. A partir dessa análise, torna-se possível avançar para um diagnóstico integrado dos erros, articulando os resultados quantitativos com a interpretação geológica.

6.3 Diagnóstico de erros

A integração das análises *macro-average* e *micro-average* permitiu estabelecer um diagnóstico consistente da natureza dos erros, evidenciando que o desempenho do modelo é condicionado pela interação entre fatores computacionais e a complexidade lito estratigráfica dos intervalos analisados. A articulação entre métricas quantitativas, distribuição dos erros por litologia e análise visual dos perfis de imagem acústica possibilitou compreender que as discrepâncias observadas não são aleatórias, mas seguem padrões diretamente associados às características geológicas e operacionais dos poços.

Nesse contexto, o comportamento do Poço B, caracterizado por número de predições inferior ao de amostras reais, pode ser atribuído à predominância de estromatólitos (ETR), configurando-se como um caso particularmente elucidativo que reforça o diagnóstico dessa litologia como um dos principais fatores de erro do modelo (Figura 12).




Figura 13 - Intervalos representativos das predições falso negativas poço B
Fonte: Elaboração própria.

Além dos condicionantes litológicos, também se observa a influência de fatores operacionais na geração de erros. Destacam-se, nesse sentido, o aumento de falsos positivos associados a cavidades remanescentes de amostras não recuperadas, bem como a presença de *breakouts* em litologias de menor granulometria e a própria porosidade *framework* dos estromatólitos. Esses elementos introduzem feições adicionais nos perfis acústicos que dificultam a distinção entre cavidades reais e artefatos, ampliando a complexidade do problema de segmentação (Figura 14).




Figura 14 - Exemplos de predições falso positivas em imagens acústicas.
Fonte: Elaboração própria.

Em síntese, o diagnóstico de erros incorporou uma análise interpretativa que articulou os resultados do modelo ao contexto geológico, permitindo compreender as causas subjacentes das discrepâncias e orientar seu aprimoramento. Os resultados evidenciam que o desempenho da ferramenta é fortemente condicionado pela variabilidade litofaciológica e pelas condições operacionais do poço, sendo particularmente influenciado pelas texturas e padrões característicos de cada rocha. Na Formação Barra Velha, a predominância de litologias microbialíticas comprometeu a taxa de detecções corretas, enquanto, na Formação Itapema, as litologias retrabalhadas dificultaram a distinção entre artefatos operacionais, feições geológicas e cavidades reais

7 CONCLUSÃO

A crescente aplicação de técnicas de *Deep Learning* nas geociências tem viabilizado avanços significativos na interpretação automatizada de dados geofísicos, sobretudo em contextos de elevada complexidade espacial e heterogeneidade litológica. Nesse cenário, as Redes Neurais Convolucionais (CNNs) consolidam-se como ferramentas robustas, capazes de extrair atributos relevantes diretamente de imagens sem a necessidade de descritores prévios. Tais arquiteturas têm sido aplicadas com sucesso em diversas escalas de análise, abrangendo desde a interpretação sísmica e o mapeamento de fácies em afloramentos até a análise detalhada de perfis de poço (FIORITI; GOUVÊA; CARNEIRO, 2025).

O presente trabalho dialoga com essas iniciativas ao aplicar modelos do tipo R-CNN à detecção e segmentação de cavidades de amostragem lateral em imagens acústicas. Diferentemente de abordagens simplificadas, baseadas exclusivamente em critérios geométricos, a utilização do aprendizado supervisionado permite ao modelo reconhecer padrões visuais complexos, incluindo variações de textura, contraste e morfologia associadas a diferentes litofácies. Nesse sentido, a proposta aqui desenvolvida avança em relação aos métodos tradicionais ao incorporar a variabilidade geológica como parte integrante do problema de detecção.

Diante da escassez de estudos voltados à automação do ajuste de profundidade por meio de CNNs, esta pesquisa apresenta uma contribuição inovadora ao demonstrar a viabilidade das R-CNNs nesse contexto. Os resultados indicam que, embora o desempenho nas métricas de classificação ainda apresente limitações, o modelo alcança elevada exatidão no posicionamento das cavidades corretamente identificadas, evidenciando maturidade na etapa de ajuste geométrico. Adicionalmente, a análise dos erros revelou que a ocorrência de falsos positivos foi superior à de falsos negativos — o que representa uma vantagem operacional estratégica. Para o intérprete, o expurgo de detecções indevidas demanda menor esforço do que a varredura manual ao longo de todo o poço para localizar cavidades omitidas pelo algoritmo. Assim, o sistema configura-se como uma ferramenta semi-autônoma, inserida em uma abordagem *Human-in-the-Loop*, na qual o geocientista desempenha papel central na validação e no aprimoramento contínuo do modelo.

Nesse contexto, torna-se imperativo o aprofundamento dos estudos acerca das litofácies de cada poço para compreender os fatores que condicionam o desempenho algorítmico, incluindo casos de equilíbrio como o observado no Poço D. A compreensão integrada entre limitações computacionais e complexidade textural reforça a necessidade de estratégias que incorporem tais variáveis ao processo de treinamento, visando ampliar a generalização frente a diferentes cenários geológicos. Por fim, os achados destacam que a convergência entre o conhecimento geológico e o aprendizado de máquina constitui o caminho mais promissor para o desenvolvimento de soluções robustas, consolidando a inteligência artificial como uma aliada estratégica, e não substituta, na interpretação geológica.

REFERÊNCIAS

AL IBRAHIM, Mustafa A.; TORLOV, Vladislav; MEZGHANI, Mokhles M. Automated verification of sidewall core recovery depth using borehole image logs. In: *SPE ANNUAL TECHNICAL CONFERENCE AND EXHIBITION*, 2021, Dubai. *Proceedings [...]*. Dubai: SPE, 2021. Disponível em: <https://doi.org/10.2118/206145-MS>. Acesso em: 26 maio 2026.

ANP – AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. *Bacia de Santos: sumário geológico e setores em oferta*. 2021. Disponível em: https://www.gov.br/anp/pt-br/rodadas-anp/rodadas-concluidas/concessao-de-blocos-exploratorios/15a-rodada-licitacoes-blocos/arquivos/areas-oferecidas/sumario_geologico_r15_santos.pdf. Acesso em: 21 abr. 2026.

BELILA, A. M. P. et al. Pore typing using nuclear magnetic resonance: an example with samples from Cretaceous pre-salt lacustrine carbonates in the Santos Basin, Brazil. *Journal of Petroleum Science and Engineering*, [S. l.], v. 190, p. 107079, 2020. DOI: <https://doi.org/10.1016/j.petrol.2020.107079>.

BICUDO, Miguel Angelo Santos. *Cálculo de porosidade e caracterização do sistema poroso em coquinas do pré-sal por modelos assistidos por especialistas*. 2025. 71 f. Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro, Instituto de Computação, Rio de Janeiro, 2025.

COLLIER, H. Petrographic analysis of thin sections of cuttings and sidewall cores: an effective method for obtaining geologic data. In: *AAPG SOUTHWEST SECTION MEETING*, 1989, San Angelo. San Angelo: AAPG, 1989.

FIORITI, Lenita de Souza; DE GOUVEA, Rodrigo Cesar Teixeira; CARNEIRO, Cleyton de Carvalho. Image logs classification with convolutional neural networks: A strategic preprocessing routine for obtaining carbonate and volcanic image facies models. *MARINE GEOSCIENCE AND ENERGY RESOURCES*, v. 189, 2026.

FITZGERALD, Peter. Wireline “creep”. In: *ABU DHABI INTERNATIONAL PETROLEUM EXHIBITION AND CONFERENCE*, 2008, Abu Dhabi. *Proceedings [...]*. Abu Dhabi: SPE, 2008. Disponível em: <https://doi.org/10.2118/118027-MS>

GO NÇALVES, Ítalo Gomes et al. Classificação automática de modelos virtuais de afloramento em 3D através de redes neurais convolucionais. In: *SIMPÓSIO DE QUANTIFICAÇÃO EM GEOCIÊNCIAS*, 10., 2025, Balneário Camboriú. *Anais de Resumos [...]*. Balneário Camboriú: Sociedade Brasileira de Geologia, 2025. p. 88. Disponível em: <https://www.geoquantificacao.com.br/assets/files/ANAIS-DERESUMO-XGEOQUANTI-2025.pdf>. Acesso em: 26 maio 2026.

GOMES, J. P. et al. Facies classification and patterns of lacustrine carbonate deposition of the Barra Velha Formation, Santos Basin, Brazilian pre-salt. *Marine and Petroleum Geology*, v. 113, p. 104176, 2020.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, v. 60, n. 6, p. 84–90, 2017. Disponível em: <https://doi.org/10.1145/3065386>. Acesso em: 26 maio 2026.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. Disponível em: <https://doi.org/10.1038/nature14539>. Acesso em: 26 maio 2026.

MAHMOUD, G. et al. Successful implementation of sidewall coring: first trial in UAE. In: *SPE/IADC MIDDLE EAST DRILLING TECHNOLOGY CONFERENCE AND EXHIBITION*, 2015, Abu Dhabi. *Proceedings* Houston: SPE, 2015.

MATA, M. L.; ALCARÁ, A. R. Análise das práticas educacionais dos bibliotecários em bibliotecas universitárias. In: *ENCONTRO NACIONAL DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO (ENANCIB)*, 17., 2016, Salvador. *Anais...* Salvador: ANCIB, 2016. Disponível em: <https://enancib.ancib.org/index.php/enancib/xiiencib/paper/view/4006>. Acesso em: 5 maio 2026.

MILANI, E. J. et al. Bacias sedimentares brasileiras: cartas estratigráficas. *Boletim de Geociências da Petrobras*, Rio de Janeiro, v. 15, n. 2, p. 183–205, 2007.

MOHRIAK, W. U.; NEMČOK, M.; ENCISO, G. South Atlantic divergent margin evolution. In: AUSTIN, J. A.; JAGOUTZ, O. (ed.). *Salt tectonics, sedimentation and hydrocarbon systems*. Tulsa: AAPG, 2008.

MOREIRA, J. L. P. et al. Bacia de Santos. *Boletim de Geociências da Petrobras*, v. 15, n. 2, p. 531–549, 2007.

MOULIN, M.; ASLANIAN, D.; UNTERNEHR, P. A new starting point for the South and Equatorial Atlantic Ocean. *Earth-Science Reviews*, v. 98, n. 1, p. 1–37, 2010.

ROURKE, M.; TORNE, J. A new wireline rotary coring tool. In: *SPE/DGS SAUDI ARABIA SECTION TECHNICAL SYMPOSIUM AND EXHIBITION*, 2011.

SANTIN, D. M. *Ciência mainstream e periférica da América Latina e Caribe*. 2019. Tese (Doutorado) – UFRGS, 2019.

SANTOS, S. M.; CALÓ, L. N. Gestão editorial. In: SILVEIRA, L.; SILVA, F. C. C. (org.). *Gestão editorial de periódicos científicos*. Florianópolis: BU Publicações, 2020.

SHRIVASTAVA, C.; SIKDAR, K. Recent advances in rotary sidewall coring. In: *BIENNIAL INTERNATIONAL CONFERENCE*, 2013.

TIAN, Miao; VERMA, Sumit; GAO, Yang. Enhancing 3D seismic facies interpretation through a modified patched deep learning approach leveraging spatio-temporal dependencies. *Computational Geosciences*, v. 29, n. 1, art. 8, 2025.

Disponível em: <https://doi.org/10.1007/s10596-024-10334-6>. Acesso em: 26 maio 2026.

TORLOV, V. S. et al. Heterogeneity and anisotropy factors. In: *SPE TECHNICAL SYMPOSIUM*, 2018.