



Erick Almeida Muhlhofer

**MODELO DE INTELIGÊNCIA ARTIFICIAL APLICADA À
DISTRIBUIÇÃO E QUANTIFICAÇÃO DO SISTEMA POROSO EM
FÁCIES-RESERVATÓRIO DE GÁS (FORMAÇÃO CABEÇAS,
DEVONIANO DA BACIA DO PARNAÍBA)**

**Trabalho Final de Curso
(Geologia)**

UFRJ
Rio de Janeiro
2025



UFRJ

Erick Almeida Muhlhofer

**MODELO DE INTELIGÊNCIA ARTIFICIAL APLICADA À
DISTRIBUIÇÃO E QUANTIFICAÇÃO DO SISTEMA POROSO EM
FÁCIES-RESERVATÓRIO DE GÁS (FORMAÇÃO CABEÇAS,
DEVONIANO DA BACIA DO PARNAÍBA)**

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:

Patrick Fuhr Dal' Bó
Lilian Souza da Silveira

Rio de Janeiro

Março de 2025

ERICK, Almeida Muhlhofer

Modelo de Inteligência artificial aplicada à distribuição e quantificação do sistema poroso em fácies reservatório de gás (Formação Cabeças, Devoniano da Bacia do Parnaíba). / Erick Almeida Muhlhofer - - Rio de Janeiro: UFRJ / IGeo, 2025.

xx, 050 p. : il.; 30cm

Trabalho Final de Curso (Geologia) – Universidade Federal do Rio de Janeiro, Instituto de Geociências, Departamento de Geologia, 2025.

Orientador: Patrick Fuhr Dal' Bó.

1. Geologia. 2. Paleontologia e Estratigrafia – Trabalho de Conclusão de Curso. I. Patrick, Fuhr Dal' Bó. II. Universidade Federal do Rio de Janeiro, Instituto de Geociências, Departamento de Geologia. III. Título.

Erick Almeida Muhlhofer

**MODELO DE INTELIGÊNCIA ARTIFICIAL APLICADA À
DISTRIBUIÇÃO E QUANTIFICAÇÃO DO SISTEMA POROSO EM
FÁCIES-RESERVATÓRIO DE GÁS (FORMAÇÃO CABEÇAS,
DEVONIANO DA BACIA DO PARNAÍBA)**

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:

Patrick Führ Dal' Bó
Lilian Souza da Silveira

Aprovada em: 28/03/2025

Por:

Orientador: Patrick Führ Dal' Bó (UFRJ)

Dra. Francisco Tognoli (DEGEL - UFRJ)

UFRJ
Rio de Janeiro
2025

Dr. Viktor Souto Louback (PPGL- UFRJ)

UFRJ
Rio de Janeiro
2025

Dedico este trabalho a todos os meus familiares e amigos que me apoiaram e principalmente meus pais que me ensinaram a nunca desistir perante qualquer desafio.

Agradecimentos

Agradeço a todos que colaboraram, não só para a elaboração do meu trabalho final, mas também para a minha formação acadêmica. Agradeço ao professor Patrick, pela orientação, paciência e apoio contínuo ao longo deste projeto. Suas valiosas sugestões e críticas construtivas foram fundamentais para o desenvolvimento deste trabalho. Aproveito para agradecer também a ENEVA, pela disponibilidade dos dados utilizados neste trabalho. Agradeço em especial aos geólogos, geofísicos e engenheiros do time de exploração em subsuperfície da ENEVA, em especial ao time de AAG (Avaliação e Acompanhamento Geológico) que foram essenciais para minha evolução técnica e pessoal, me oferecendo conselhos, ensinamentos e principalmente fazendo eu me sentir em casa durante os dois anos de estágio na companhia. Agradeço a todos os meus colegas de graduação, principalmente à meus amigos do grupo “Painéis das painéis”, pela parceria e aprendizado conjunto durante a graduação. Agradeço a minha querida namorada, pelo apoio contínuo, companheirismo e momentos felizes que me ajudaram a superar obstáculos. Por fim, agradeço também a minha família por todo o suporte nos momentos bons e ruins e por todas as lições de vida que me permitiram chegar aonde estou.

O conhecimento te dá o poder de mudar eventos. (Autor desconhecido)

Resumo

ALMEIDA MUHLHOFER, Erick. **Modelo de Inteligência artificial aplicada à distribuição e quantificação do sistema poroso em fácies reservatório de gás (Formação Cabeças, Devoniano da Bacia do Parnaíba)**. 2025. xx,049 f. Trabalho Final de Curso (Geologia) – Departamento de Geologia, Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

Este trabalho aplica um modelo de inteligência artificial para a quantificação da porosidade em fácies-reservatório de gás da Formação Cabeças (Devoniano da Bacia do Parnaíba). Foram analisadas 38 lâminas delgadas provenientes de plugues de testemunhos e comparadas com dados de petrofísica laboratorial e contagem visual de pontos. Os resultados indicam que a porosidade predominante é intergranular, variando de 6,66% a 17,76%, com a presença de argilas e cimentação carbonática influenciando sua distribuição. A inteligência artificial demonstrou boa correlação com a contagem visual de pontos ($R^2 = 0,94$), mas dificuldades foram observadas em amostras com alto teor de argilas. A análise estatística permitiu a definição de três conjuntos principais de características permo-porosas, sendo o associado a canais de maré o de melhor potencial como reservatório. A aplicação da inteligência artificial se mostrou promissora para a caracterização rápida e objetiva da porosidade, contribuindo para a avaliação de reservatórios de gás natural na Bacia do Parnaíba.

Palavras-chave: Inteligência artificial, porosidade, fácies-reservatório, Formação Cabeças, Bacia do Parnaíba.

Abstract

ALMEIDA MUHLHOFER, Erick. Artificial intelligence model applied to the distribution and quantification of the porous system in gas reservoir facies (Cabeças Formation, Devonian of the Parnaíba Basin). 2025. xx, 049 f. Trabalho Final de Curso (Geologia) – Departamento de Geologia, Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

This study applies an artificial intelligence model to quantify porosity in gas reservoir facies of the Cabeças Formation (Devonian of the Parnaíba Basin). A total of 38 thin sections from core plugs were analyzed and compared with petrophysical laboratory data and point-counting techniques. Results indicate that intergranular porosity is predominant, ranging from 6.66% to 17.76%, with clay presence and carbonate cementation influencing its distribution. The artificial intelligence model showed a good correlation with visual point counting ($R^2 = 0.94$), although difficulties were observed in samples with high clay content. Statistical analysis identified three main petrophysical groups, with tidal channel-associated facies showing the best reservoir potential. The application of artificial intelligence proved promising for the rapid and objective characterization of porosity, contributing to the evaluation of gas reservoirs in the Parnaíba Basin.

Key-Words: Artificial intelligence, porosity, reservoir facies, Cabeças Formation, Parnaíba Basin.

Lista de figuras

Figura 1 – Localização do Poço A no campo de Gavião Mateiro (GVM), perfurado nas imediações do município de São Domingos do Maranhão, na porção nordeste da Bacia do Parnaíba.....	10
Figura 2 – Mapa de isópacas da Formação Cabeças evidenciando espessamento da unidade para leste e afinamento para oeste.....	12
Figura 3 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A (lâminas L1 a L3).....	14
Figura 4 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A (lâminas L4 a L12).	15
Figura 5 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A (lâminas L13 a L20).....	16
Figura 6 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A (lâminas L21 a L29).....	17
Figura 7 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A (lâminas L30 a L38).....	18
Figura 8 – Exemplo de lâmina delgada mostrando as diferentes magnificações utilizadas para a etapa de pré-processamento “image subset”.....	19
Figura 9 – Esquema de rede neural arquitetada em U.	20
Figura 10 – Fluxo de treinamento do modelo de inteligência artificial em lâmina delgada.....	21
Figura 11 – Gráfico de dispersão mostrando a correlação entre os dados de porosidade obtidos pelas diferentes técnicas utilizadas no trabalho.....	22
Figura 12 – Imagens de lâmina delgada correspondente à amostra L7 pertencente à fácies Afect.....	23
Figura 13 – Interpretação automática feita pelo modelo de inteligência artificial na amostra L7 (fácies Afect).....	24
Figura 14 – Imagens de lâmina delgada correspondente à amostra L34 pertencente à fácies Amfec.....	25
Figura 15 – Interpretação automática feita pelo modelo de inteligência artificial na amostra L34 (fácies Amfec).....	26
Figura 16 – Imagens de lâmina delgada correspondente à amostra L5 pertencente à fácies AmfM.....	27
Figura 17 – Interpretação automática feita pelo modelo de inteligência artificial na amostra L5 (fácies AmfM).....	28

Figura 18 – Gráfico de dispersão da poro-permeabilidade separado por fácies.....	29
Figura 19 – Imagens da amostra L4 evidenciando preenchimento do espaço poroso por argila.....	30
Figura 20 – Gráfico de dispersão da poro-permeabilidade das amostras normalizado.....	31
Figura 21 – Gráfico de dispersão da poro-permeabilidade do Conjunto 1.....	32
Figura 22 – Imagens de lâmina delgada da amostra L8 evidenciando feições de argila e dissolução de feldspatos.....	33
Figura 23 – Perfil sedimentológico evidenciando a associação de fácies de canais de maré.....	34
Figura 24 – Imagem de lâmina delgada da amostra L10 com presença de cristais de anidrita preenchendo o espaço intergranular.....	35

Tabelas

Tabela 1 – Código das lâminas delgadas utilizadas neste estudo com as respectivas profundidades e fácies sedimentares de onde foram extraídas.....	45
Tabela 2 – Código das lâminas delgadas utilizadas neste estudo com os respectivos dados de porosidade e permeabilidade medidas em laboratório.....	21
Tabela 3 – Código das lâminas delgadas utilizadas neste estudo com as respectivas medidas obtidas na contagem de 300 pontos e no modelo de inteligência artificial.....	47

Sumário

Agradecimentos	vi
Resumo	viii
<i>Abstract</i>	ix
Lista de figuras	x
Lista de tabelas	x
Lista de abreviaturas e siglas	x
Lista de símbolos	x
1 INTRODUÇÃO	1
1.1 Referencial teórico.....	3
1.2 Objetivo e área de estudo.....	3
2 CONTEXTO GEOLÓGICO.....	5
1.1 Bacia do Parnaíba.....	5
1.2 Sequência Devoniana.....	5
1.3 Formação Cabeças.....	6
3 MÉTODOS.....	8
4 REULTADOS E DISCUSSÕES.....	20
4.1 Porosidade e permeabilidade medidas em laboratório.....	20
4.2 Contagem visual de pontos.....	21
4.3 Porosidade quantificada por Inteligência Artificial (I.A.)	22
4.4 Análise de fácies.....	24
4.4.1 Afect (Arenito fino com estratificação cruzada tabular).....	25
4.4.2 Amfec (Arenito muito fino com estratificação cruzada cavalgante).....	28
4.4.3 AmfM (Arenito muito fino maciço).....	31
4.4.4 Amostra fora dos padrões.....	35
4.4.5 Conjunto de dados 1.....	37
4.4.6 Conjunto de dados 2.....	39
4.4.7 Conjunto de dados 3.....	41
CONCLUSÃO.....	43
Apêndice A.....	45
Apêndice B.....	47
Referências bibliográficas	49

1 INTRODUÇÃO

Apesar da vocação natural por energias renováveis, o Brasil vem sofrendo desproporcionalmente com as alterações climáticas e de ciclos hidrológicos, chegando a variações de até 1/3 da intensidade de emissões de carbono do setor elétrico devido apenas a estiagens, baixas na produção hidrelétrica e migração para opções carbonizadas (IPCC, 2022). Protagonizando os planos futuros da transição energética, o setor elétrico passa também por mudanças estruturais quantitativas. A demanda elétrica global cresce mundialmente de forma resiliente, mesmo após cenários de crise, como a pandemia de covid-19 e a guerra na Ucrânia, chegando a 2% de crescimento em 2022 (IEA, 2023).

O Pantanal brasileiro, por exemplo, vem sendo castigado por uma estiagem histórica, com chuvas irregulares e déficit hídrico, resultando em seca severa ou extrema em grande parte da região (Cemaden, 2024). A dependência hídrica do sistema energético brasileiro, com o agravamento dos eventos hidrológicos extremos, pode comprometer a segurança energética nacional, migrando a fontes carbonizadas em momentos de crise (EPE, 2023).

Nesse contexto, a exploração da molécula de gás natural para a geração termoelétrica de energia pode se provar uma alternativa viável para a segurança energética brasileira no contexto de crise hídrica citado anteriormente, corroborando com a necessidade mundial de reduzir as emissões de CO₂ já que é menos poluente que outras fontes de combustíveis fósseis.

A Bacia do Parnaíba foi descrita por Rodrigues(1995) como pouco atrativa para exploração de petróleo ou gás devido ao relativo soterramento raso para maturação dos intervalos geradores, restringindo-a ao efeito térmico das intrusões máficas. Contudo, nos últimos 15 anos, a bacia tem se revelado como uma importante fonte de recursos energéticos para a região Norte-Nordeste, principalmente após a descoberta e desenvolvimento dos campos de Gavião Azul e Gavião Real pelas empresas OGX/PGN/Eneva.

1.1 Referencial teórico

A identificação de reservatórios de alta qualidade constitui um dos grandes desafios da indústria petrolífera, sendo de fundamental importância para o sucesso exploratório e o aumento de reservas. No entanto, a busca por estes reservatórios é uma tarefa por vezes complexa, uma vez que eles podem variar significativamente em termos de porosidade, permeabilidade e composição mineralógica.

O gás natural é definido como o hidrocarboneto de baixo peso molecular que se encontra no estado gasoso em condição de temperatura e pressão (20°C e 1atm) (Allen & Allen, 2013). Pode ser classificado, de acordo com sua composição molecular, em seco, quando formado essencialmente por moléculas de metano (CH₄), ou úmido, quando formado por componentes mais pesados (Metano a pentano) (Jahn et al., 2008). O gás natural pode ser originado como um subproduto da geração de petróleo e, nesse caso, é denominado gás associado (Bjorlykke, 2010). Outra possibilidade é que sua ocorrência esteja relacionada a transformações do petróleo, sendo conhecido como gás não associado.

A geração termelétrica a partir da molécula de gás natural tem mostrado grande importância na matriz elétrica brasileira pois, mesmo sendo uma das mais renováveis do mundo, depende pontualmente da geração termelétrica para garantir a segurança energética do país (Netto, 2024). A Bacia do Parnaíba se encontra numa região estratégica nacional, onde o complexo termelétrico da ENEVA, alimentado pelo gás natural extraídos da Formação Cabeças e da Formação Poti, consegue alimentar a região nordeste e despachar energia elétrica pelo SIN (Sistema Integrado Nacional) para outras regiões do Brasil.

A análise geológica com base na petrografia e petrofísica da Formação Cabeças, um dos principais intervalos reservatório da bacia e objeto de estudo desta dissertação, visa a identificação dos parâmetros de porosidade, bem como os fatores que a influenciam para que seja possível entender melhor o sistema poroso e auxiliar a identificação de reservas de

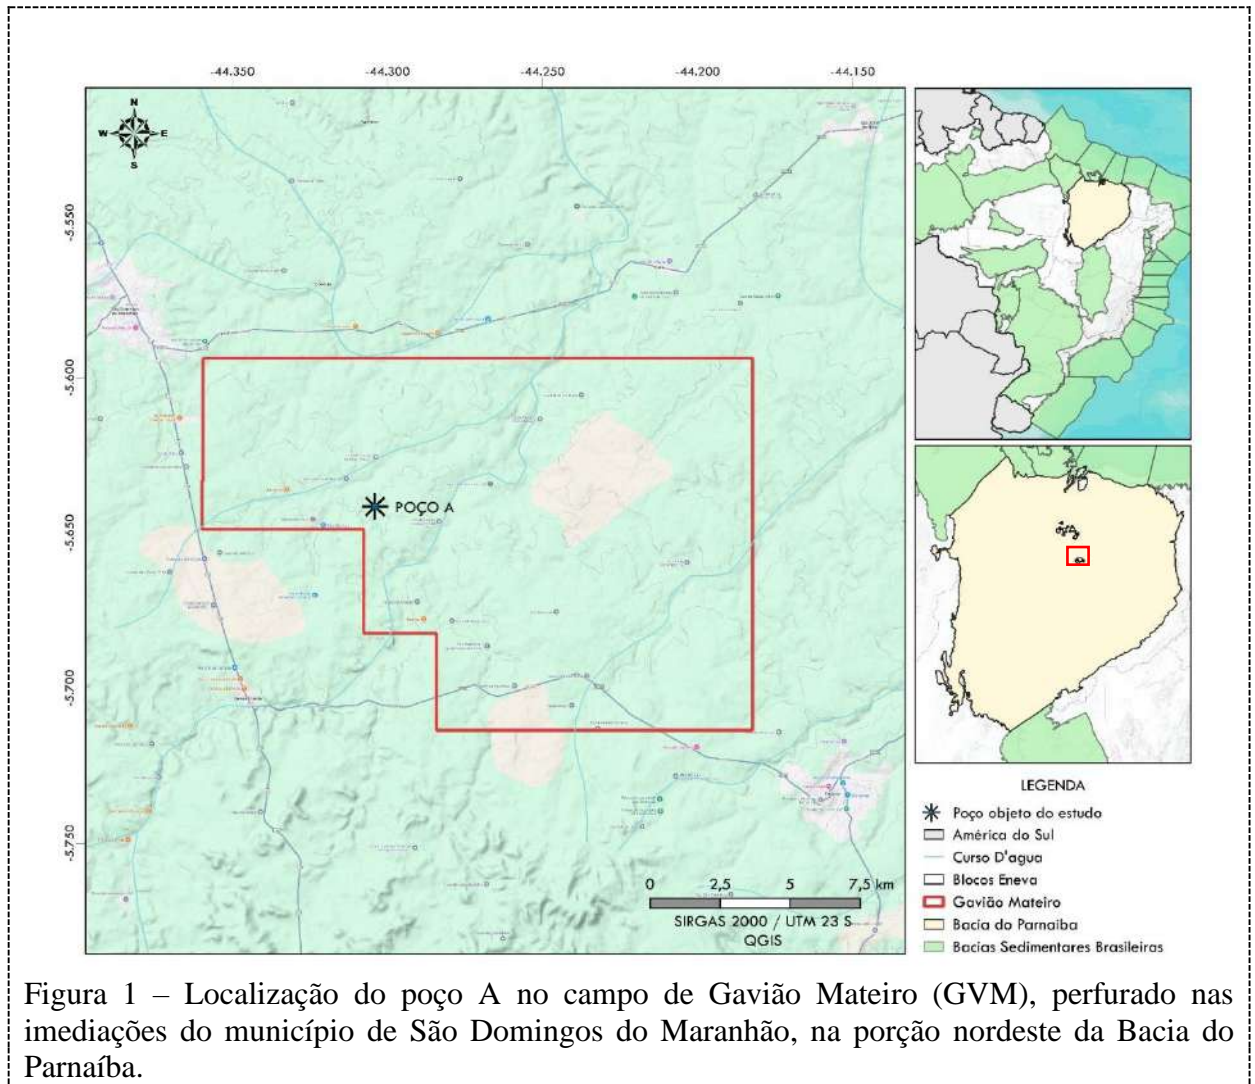
hidrocarbonetos (principalmente o gás natural) num contexto de viabilidade e segurança energética.

1.2 Objetivo e área de estudo

O objetivo deste estudo é a aplicação de um modelo de inteligência artificial para a quantificação da distribuição do sistema poroso em fácies-reservatório de gás da Formação Cabeças, a partir da comparação de dados de porosidade obtidos pela análise petrofísica em laboratório e dados de quantificação de lâminas delgadas utilizando imagens digitais de alta resolução.

A área da Bacia do Parnaíba escolhida para o desenvolvimento deste estudo foi o campo de Gavião Mateiro (GVM), operado pela empresa ENEVA, localizado próximo a cidade de São Domingos do Maranhão (Figura 1). O gás natural produzido nesse campo é escoado por gasodutos para o complexo termoeletrico do Parnaíba, aproximadamente a 150 km a norte do campo.

Para a realização deste trabalho, utilizou-se como principal fonte de dados os 18 metros de testemunhos adquiridos em um dos poços do referido campo, aqui denominado de Poço A por razões de confidencialidade comercial.



2 CONTEXTO GEOLÓGICO

2.1 Bacia do Parnaíba

A Bacia do Parnaíba é uma bacia de interior cratônico, localizada na região nordeste do território brasileiro, ocupando uma área de 600.000 km². Distribui-se pelos estados do Piauí, Maranhão, Pará, Tocantins, Goiás e Ceará. Apresenta forma elíptica, com eixo de maior alongação orientado para NE-SO com um comprimento de aproximadamente 1000 km. Em seu depocentro, a espessura da coluna sedimentar atinge cerca de 3.500m (Vaz et al., 2007). A bacia possui sucessão geológica que vai do Cambriano ao final do Cretáceo. A formação geológica foco deste estudo é a Formação Cabeças, inserida no intervalo estratigráfico da Sequência Devoniana da bacia.

2.2 Sequência Devoniana

Composta pelas formações Itaim, Pimenteiras, Cabeças, Longá e Poti, esta seção Devoniano-Carbonífero do Grupo Canindé encontra-se sobreposta ao Grupo Serra Grande por uma discordância erosional, paralela, relacionada a uma ampla regressão mundial, que ocasionou a migração da linha de costa da África do Norte, entre Argélia e Marrocos, por mais de 1.000 Km, simultaneamente a regressão das bacias brasileiras (Caputo e Lima, 1984). As fácies deste grupo apresentam-se dominadas por processos de correntes de marés e tempestades, sendo as primeiras descrições e interpretações de tempestitos no Brasil feitas por Della Fávera (Della Fávera, 2001), posteriormente detalhadas pelo mesmo em Della Fávera (1990). Estima-se que sua espessura seja superior a 1.000 m, na porção leste da bacia.

2.3 Formação Cabeças

Com idade Givetiana-Frasniana (aproximadamente 387 a 372 milhões de anos), a Formação Cabeças é formada predominantemente por arenitos finos a médios associados a arenitos grossos, depositados em paleoambiente fluvial/estuarino também com influência periglacial (Fortes, 1990). Interpreta-se um paleoambiente de sedimentação nerítico-plataformal, dominado por corrente de maré (Góes; Feijó, 1994) e eventual influência periglacial registrada por diamictitos, nos quais ocorrem algumas superfícies estriadas (Caputo, 1984).

Nesta unidade, ocorrem feições de lobos sigmoidais ou sigmóides, extremamente comuns nas bacias brasileiras, ocorrendo também nas formações Marfim e Pojuca (Bacia do Recôncavo) e na Formação Furnas (Bacia do Paraná) (Della Fávera, 2001). Com base no mapa de isópacas (Figura 2) confeccionado à partir dos dados dos poços da Eneva, estima-se uma espessura entre 100 e 400 m, com espessamento da formação para leste da bacia.

O mapa de distribuição da Formação Cabeças apresentado na figura 2 foi desenvolvido utilizando o software Petrel, onde foram utilizados 76 poços da Bacia do Parnaíba, considerando a espessura de arenitos da unidade litoestratigráfica em cada ponto. A legenda do mapa mostra as cores mais frias como a maior espessura e as cores mais quentes como a menor espessura. As linhas de contorno são referentes a espessura da Formação Cabeças.

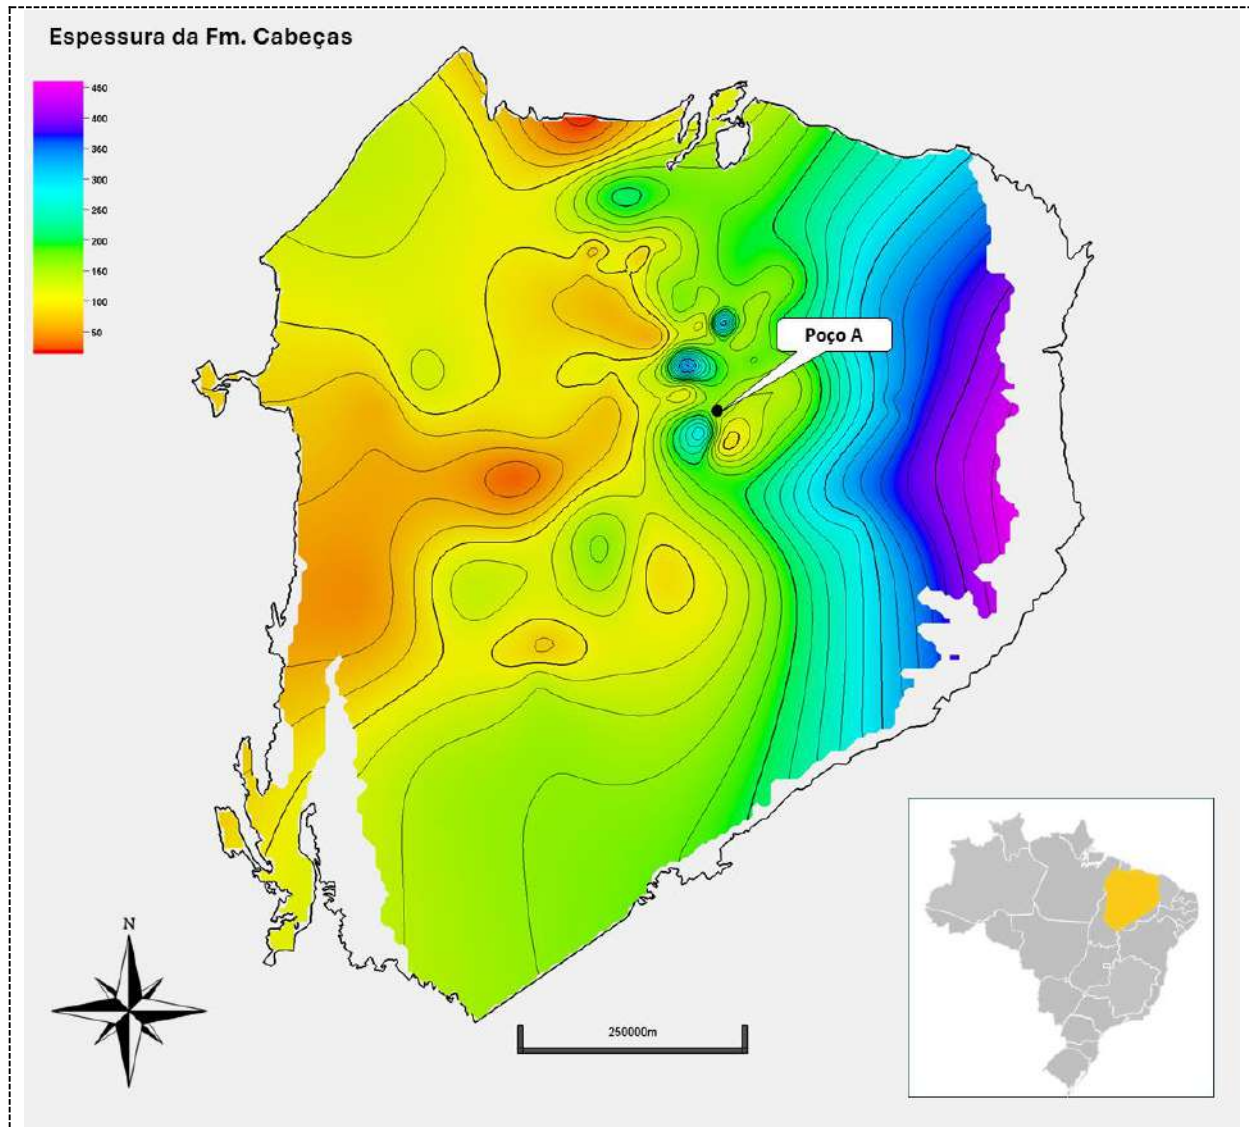


Figura 2 – Mapa de isópacas da Formação Cabeças evidenciando espessamento da unidade para leste e afinamento para oeste. O principal depocentro da unidade está localizado no leste da área de estudo. A área em amarelo no mapa do Brasil indica a localização da Bacia do Parnaíba.

3 MÉTODOS

Devido a questão de confidencialidade de dados, o poço utilizado neste trabalho, será denominado de Poço, e sua perfuração ocorreu no ano de 2022. Durante a perfuração da Formação Cabeças foi realizada uma operação de testemunhagem, a partir da qual foi cortado e recuperado um testemunho contínuo com 18,16 m de comprimento. Após recuperado em superfície, o testemunho foi dividido em 19 partes de aproximadamente 1 m e colocado em caixas específicas para o transporte ao laboratório contratado para realização das análises laboratoriais padrão e complementares.

A descrição do testemunho foi realizada pelas geólogas da equipe de avaliação e acompanhamento geológico da ENEVA. Durante esse processo, analisa-se aspectos litológicos como granulometria, seleção, arredondamento, estruturas sedimentares, cimentação e outros, a fim de descrever e empilhar as fácies que caracterizam os processos sedimentológicos. A partir do empilhamento de fácies e associação do conjunto de processos foi possível inferir o paleoambiente em que foi depositado a rocha.

Após a descrição do testemunho, 106 plugues cilíndricos de rocha com dimensões aproximadas de 5 cm de comprimento por 2,5 cm de diâmetro foram retirados do testemunho. Os plugues cilíndricos de rocha foram submetidos a extração *SOXLET*, que consiste numa limpeza para retirada de sais, fluido de perfuração e impurezas das amostras, e então foi feito o recorte para a confecção das lâminas delgadas. Desses 106 plugues foram selecionadas 38 amostras de rocha pertencentes às fácies Amfec (Arenito muito fino com estratificação cruzada cavalgante), AmfM (Arenito muito fino maciço) e Afect (Arenito fino com estratificação cruzada tabular), que correspondem a 57% das fácies descritas no testemunho. As lâminas delgadas utilizadas neste estudo foram adquiridas a partir dos plugues citados acima e escaneadas em alta resolução pelo equipamento scanner Axioscan 7 da marca ZEISS. A

listagem das 38 lâminas delgadas selecionadas e a posição delas no testemunho estão dispostas na Tabela 1 e nas imagens a seguir (Figuras 3 a 7).



Figura 3 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A. A posição das lâminas delgadas está representada pelas letras L1 a L3.

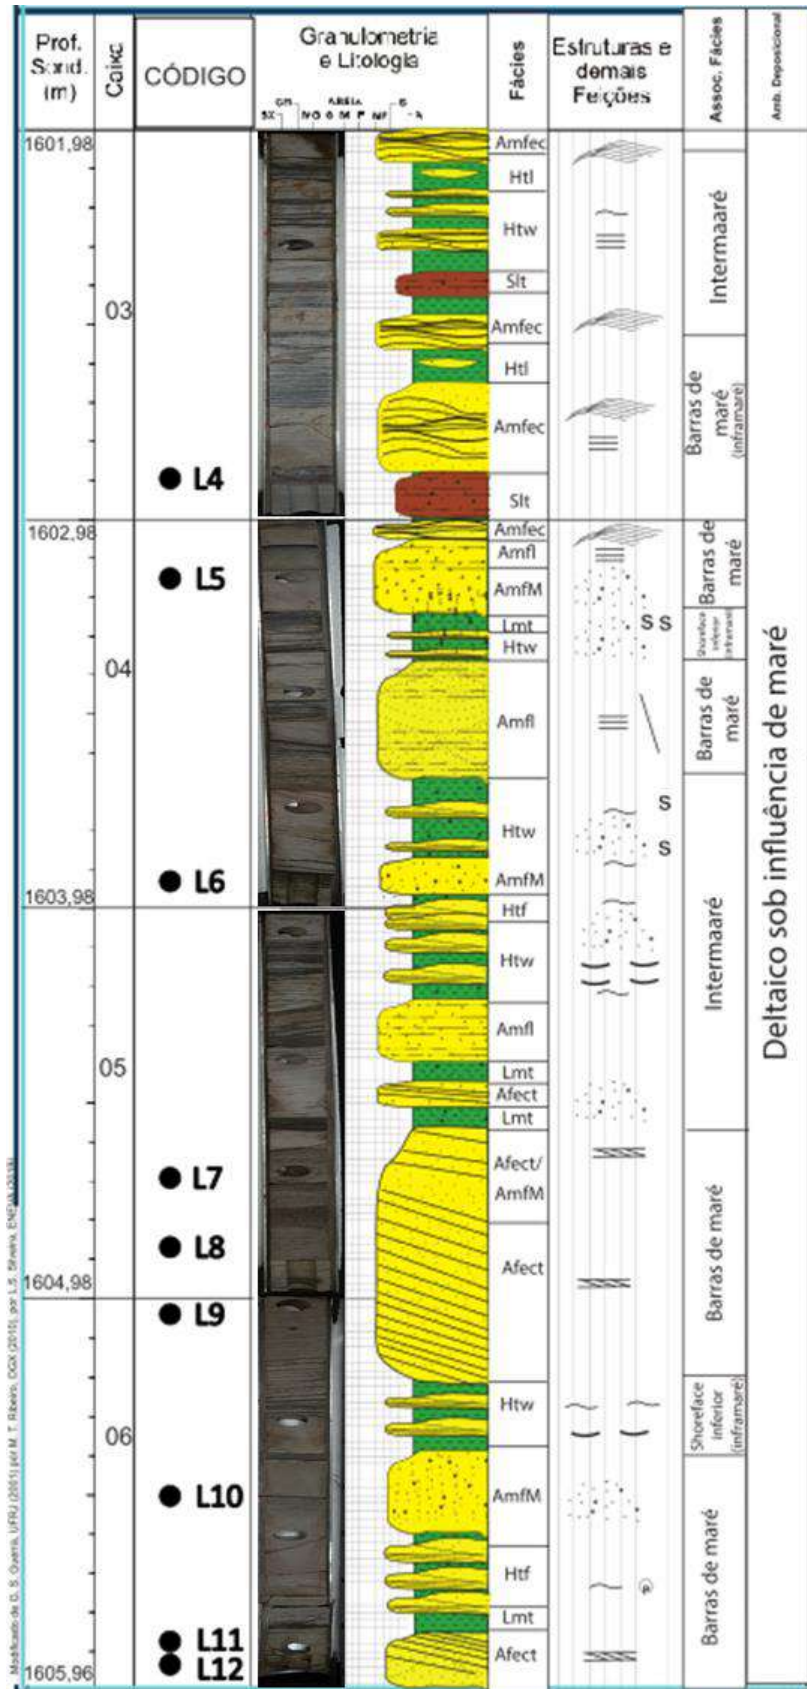


Figura 4 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A. A posição das lâminas delgadas está representada pelas letras L4 a L12.

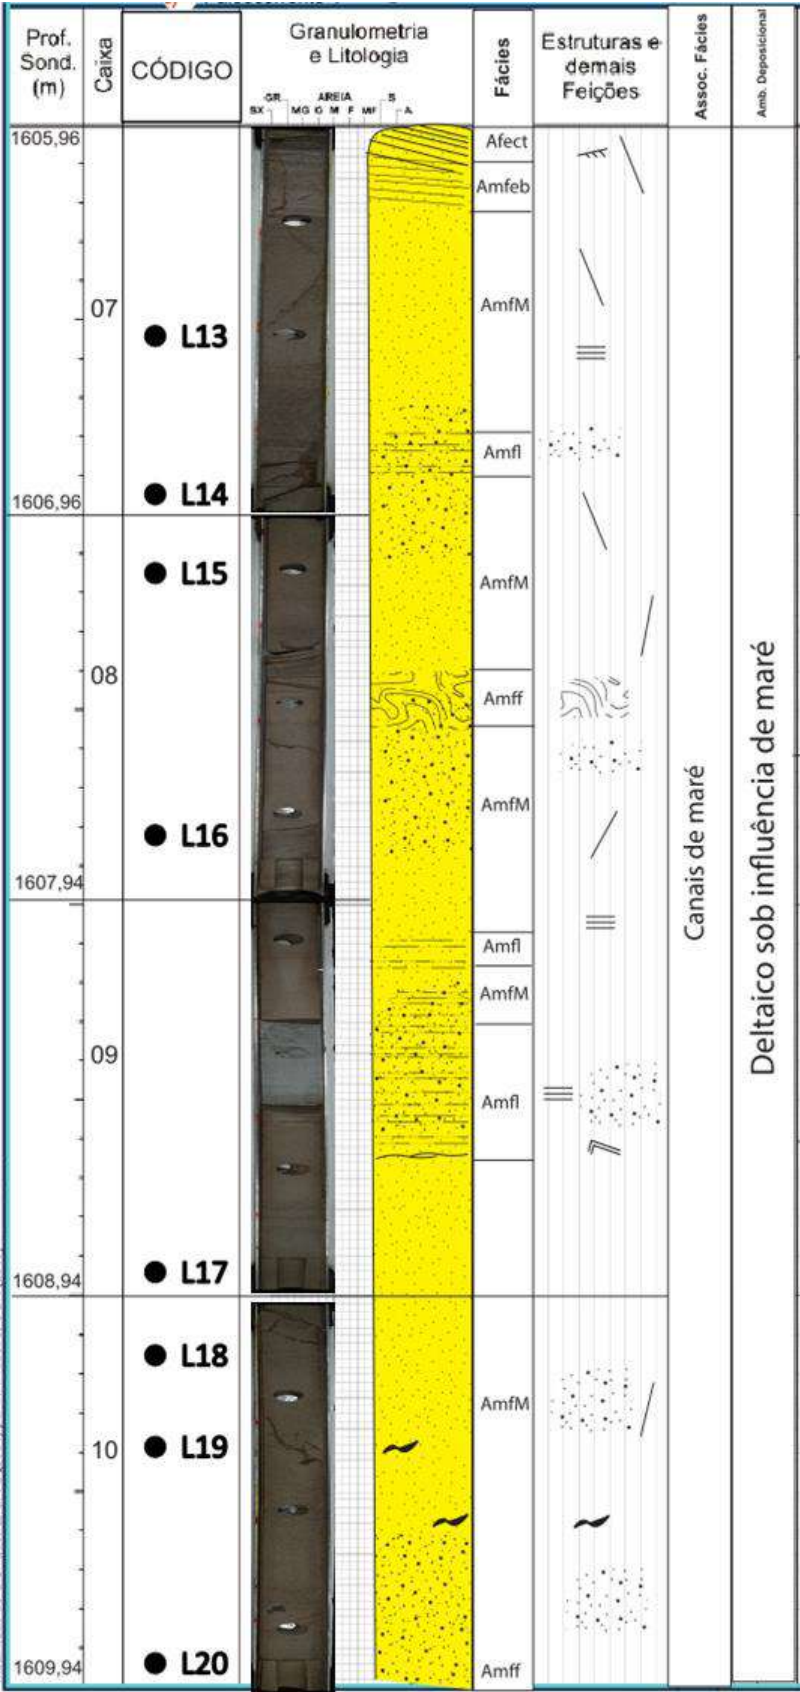


Figura 5 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A. A posição das lâminas delgadas está representada pelas letras L13 a L20.




Figura 6 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A. A posição das lâminas delgadas está representada pelas letras L21 a L29.

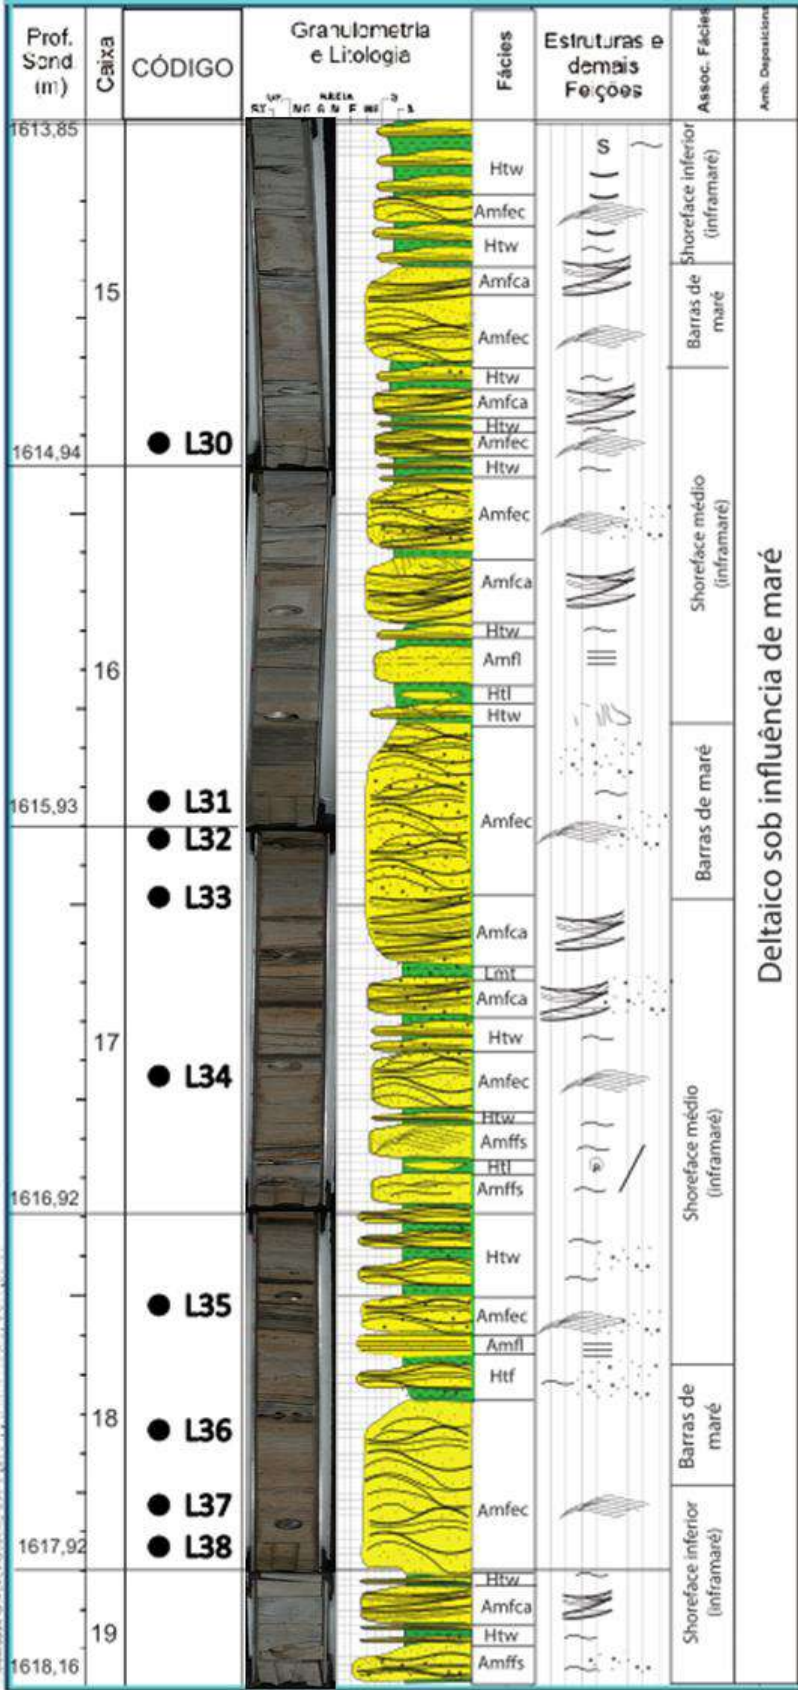


Figura 7 – Perfil sedimentológico mostrando o empilhamento vertical e a distribuição das fácies sedimentares no Poço A. A posição das lâminas delgadas está representada pelas letras L30 a L38.

Após a escolha do material base e seleção das lâminas delgadas, foram feitas análises para descrever e quantificar a porosidade em microescala e os aspectos que influenciam seu comportamento.

Para tal, primeiramente foi realizada uma contagem estatística de pontos a fim de recolher informações características sobre o arcabouço, matriz e espaço poroso da rocha. A contagem visual de pontos é uma técnica comumente utilizada para quantificar aspectos em lâminas delgadas (Tucker, 2001). Realizou-se a contagem de 300 pontos espaçados regularmente a uma distância de 0,062 mm nas lâminas de arenitos muito finos e de 0,125 mm nas lâminas de arenitos finos representativas das fácies selecionadas.

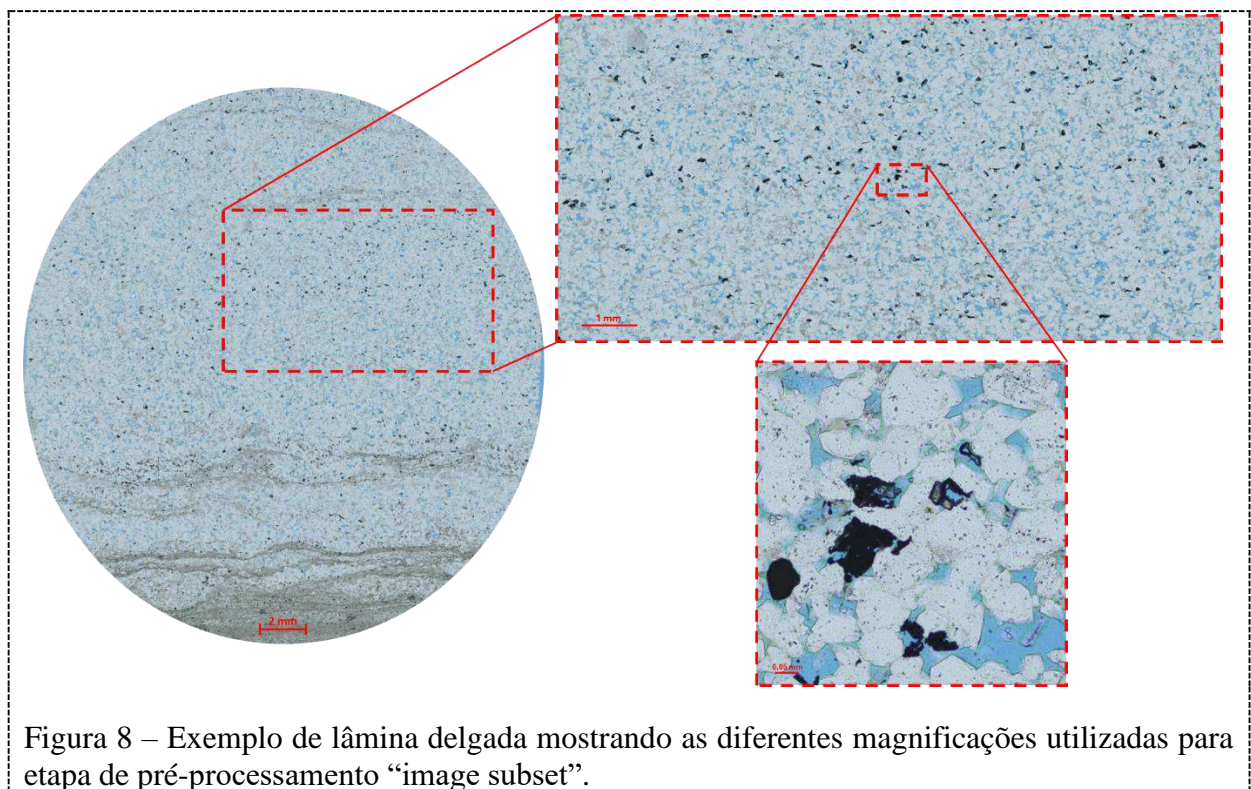
Durante a contagem de pontos também foi realizada a descrição das características do grão ou do poro correspondente a cada ponto, tais como: tamanho do grão, arredondamento, composição mineralógica do grão ou da matriz e aspectos diagenéticos de cimentação. Já para os poros, foram descritos o tipo de poro e seu diâmetro do eixo maior. A partir dos dados obtidos pela contagem e descrição do grão e/ou poro também foram realizadas análises para definição dos principais parâmetros de granulometria média da rocha, grau de seleção do arcabouço da rocha, porcentagem de poros, porcentagem de grãos, porcentagem de materiais finos e o tipo de porosidade predominante. Após a finalização das análises descritas acima, iniciou-se a etapa de treinamento e aplicação do modelo de inteligência artificial.

O treinamento e aplicação do modelo de inteligência artificial seguiu 4 etapas: (i) escaneamento e digitalização das lâminas delgadas; (ii) pré-processamento das imagens escaneadas; (iii) treinamento do modelo de inteligência artificial; e (iv) aplicação do método nas imagens de lâmina para o cálculo de porosidade digital.

O escaneamento das lâminas foi executado utilizando o “Axioscan 7”, equipamento da ZEISS que transforma essas lâminas delgadas em imagens digitais de alta resolução (2900 pixel/milímetro) em 6 canais polarizados e no canal plano paralelo (*brightfield*).

Ao contrário dos microscópios polarizadores tradicionais com desvio no campo de visão durante a rotação da platina, os sistemas convencionais de microscopia do “scanner” ZEISS Axioscan 7 realizam análises de alinhamento de imagens sequenciais adquirindo ângulos de polarização ortogonais enquanto a platina não está em movimento, tornando assim possível a identificação semiautomática inteligente.

Foram selecionadas 38 imagens digitais de alta resolução de lâminas delgadas, digitalizadas pelo scanner “Axioscan 7” da ZEISS, sendo elas referentes às fácies reservatório de gás da Formação Cabeças. A partir dessas imagens foram aplicadas etapas de pré-processamento, como o *resample* e *image subset* (Figura 8) para habilitar o treinamento do modelo de inteligência artificial de forma mais eficiente, otimizando o uso do hardware disponível.



As etapas de pré-processamento objetivaram diminuir o tamanho digital da imagem com pouca perda de resolução, de forma que os contatos entre os grãos, suas respectivas texturas e cores de refração fossem mantidas e permitissem a interpretação de forma qualitativa para o treinamento do modelo de inteligência artificial. O modelo treinado utilizou oito recortes de imagem de dimensões milimétricas iguais.

O modelo de inteligência artificial utiliza o módulo “Zeiss Intellesis”, embutido no *software* do equipamento, e que possibilita até sete técnicas de *machine learning*, desde as feições reconhecidas como básicas, *basic features*, até as complexas, *deep features*, variando de 25 até 128 parâmetros de análise. Para esta análise, foi utilizada a aplicação do algoritmo *basic feature 33*. Efetivamente, este algoritmo aplica uma série de análises de recursos para criar um vetor de descrição final composto por 33 parâmetros. Foram aplicadas redes neurais de arquitetura em U (Figura 9), que utiliza métodos convolucionais matemáticos para comparar as informações atribuídas a cada pixel e seus pixels vizinhos.

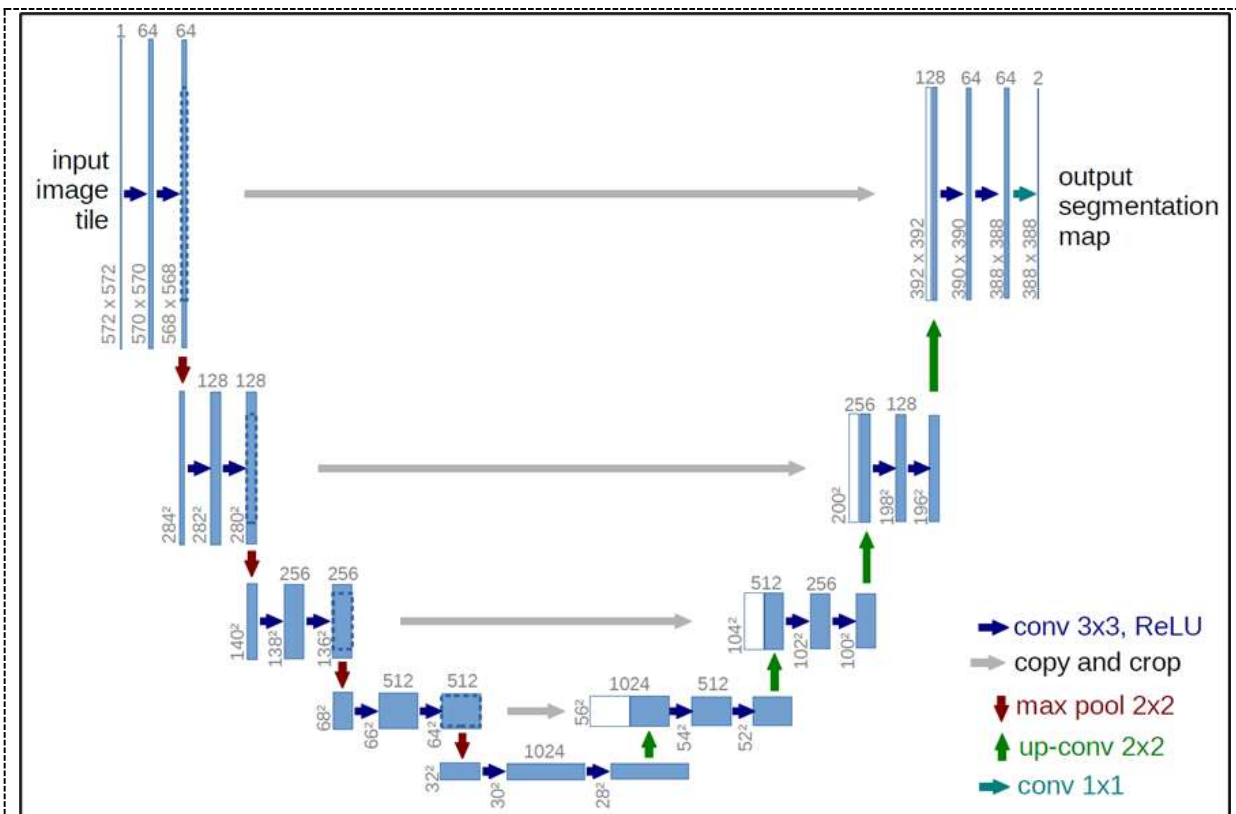


Figura 9 – Esquema de rede neural arquitetada em U. Adaptado de (Ronneberger, et al., 2015).

O treinamento do modelo de inteligência artificial foi realizado no módulo *Intellesis trainable segmentation* dentro do software *ZEN*, da empresa *ZEISS*, sendo selecionados oito

recortes de imagens representativos da diferença textural entre o arcabouço da rocha e o espaço poroso, representado nas lâminas delgadas pela resina epóxi de cor azul.

A interpretação foi realizada manualmente, utilizando a imagem de lâmina delgada em dois canais: (i) canal plano-paralelo (*Brightfield*) e (ii) canal de polarização circular (*Cpol*). Ademais, as amostras foram segmentadas em duas classes: poro e não-poro. O *software* identifica as características ópticas da imagem de cor, saturação e intensidade atribuídas a cada pixel da área designada pelo intérprete, nos dois canais das imagens. Após a identificação primária do intérprete, o modelo devolve uma interpretação extrapolada para uma área maior em relação aos recortes escolhidos para o treinamento e, então, são feitas correções para a melhoria da assertividade do reconhecimento automático (Figura 10).

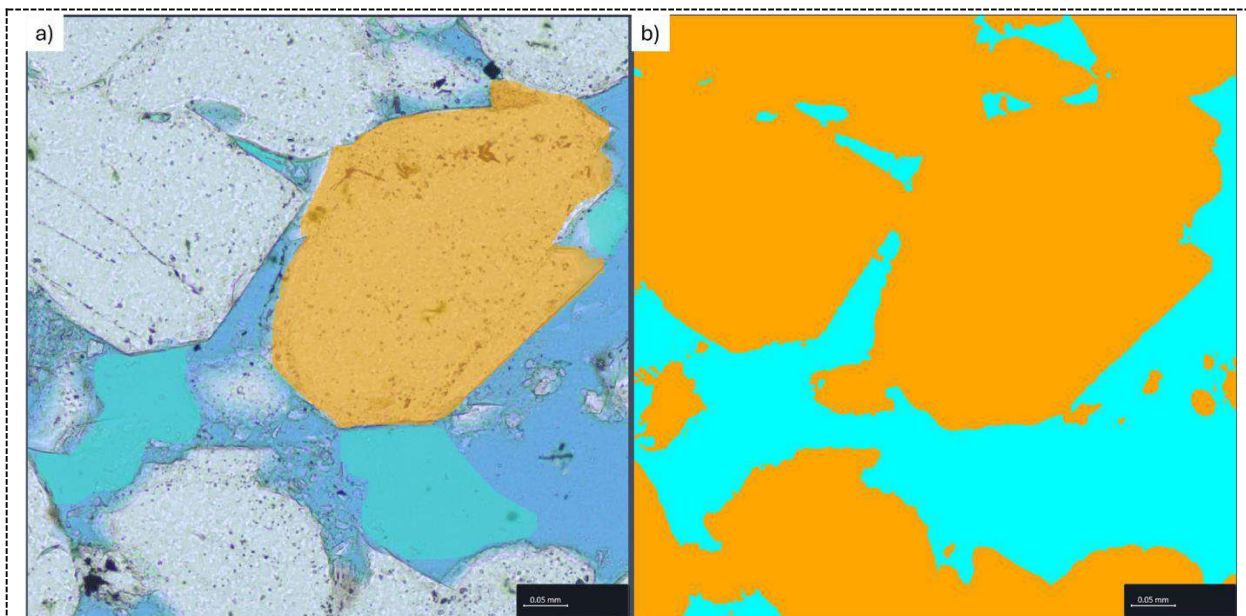


Figura 10 – Exemplo do fluxo de treinamento do modelo de I.A. em lâmina delgada. a) Porção geográfica da lâmina designada manualmente. A cor laranja clara representa a classe não-poro e a cor azul clara representa a classe poro. b) Devolutiva inferida automaticamente pelo modelo de I.A. A cor laranja representa a classe não-poro e a cor azul clara representa a classe poro.

Uma vez que o modelo é treinado manualmente, o mesmo pode ser aplicado às imagens de lâminas, independentemente da litologia, composição, proveniência, mineralogia, etc. O método tradicional de identificação de porosidade em lâminas delgadas é realizado pela contagem de pontos espaçados regularmente de forma arbitrária e depende da observação visual de um petrógrafo experiente ao microscópio. O trabalho do intérprete demanda bastante tempo e as estimativas são feitas de forma visual, geralmente sem nenhum auxílio de técnicas de

tratamento de imagens computacionais e matemáticas, assim como foi executado neste trabalho para a comparação de resultados obtidos.

As análises laboratoriais de petrofísica básica de 38 plugues foram realizadas pelo laboratório contratado pela ENEVA. Nesta análise, após limpeza das amostras, o cilindro de rocha é colocado em um porosímetro / permeâmetro. Esse equipamento simula a pressão de confinamento de reservatório e induz o fluxo de dois tipos de fluido para o cálculo de permeabilidade e porosidade no plugue de rocha. Para o cálculo da porosidade, o fluxo utilizado é o gás Hélio e para a permeabilidade o fluxo utilizado é o gás nitrogênio (N₂). Para o cálculo de porosidade são utilizados dois métodos distintos: porosidade ambiente e porosidade NCS. Para a porosidade tipo NCS é feito um cálculo de correção levando em consideração a pressão de confinamento do ponto de profundidade correspondente a amostra de rocha.

A porosidade e permeabilidade obtidas na petrofísica foram analisadas utilizando o método estatístico “K-means” a fim de fazer uma separação de conjuntos com características similares. Para isso foi plotado um gráfico com os dados de porosidade e permeabilidade normalizados. Nos dados analisados, o agrupamento foi definido em 3 conjuntos separados por características permo-porosas distintas explicadas por mudanças no comportamento sedimentológico e textural das amostras analisadas.

4 RESULTADOS E DISCUSSÕES

4.1 Porosidade e permeabilidade medidas em laboratório

Os resultados obtidos nas análises de porosidade e permeabilidade executadas em laboratório estão dispostos na tabela 2. Como mencionado, para o cálculo de porosidade foram utilizados dois métodos: tipo ambiente e tipo NCS. A porosidade ambiente obtida nas amostras varia de 6,66 a 17,76%, a porosidade tipo NCS varia de 5,88 a 16,94% e a permeabilidade de 0,1 a 150 mD. As principais variações de porosidade e permeabilidade registram as mudanças nas propriedades geológicas de granulometria, diagênese (cimentação e dissolução) e elementos argilosos entre os poros.

Tabela 2 – Código das lâminas delgadas utilizadas neste estudo com os respectivos dados de porosidade e permeabilidade medidas em laboratório.

Código	Porosidade de Laboratório		Permeabilidade de Laboratório (mD)
	Ambiente (%)	Tipo NCS (%)	
L1	13,17	12,57	13,7
L2	14,19	13,49	28,8
L3	16,34	15,66	96,8
L4	6,66	5,88	0,1
L5	15,84	15,31	14,2
L6	14,21	13,65	0,59
L7	16,08	15,33	71,6
L8	14,45	13,63	3,74
L9	17,4	16,55	92,2
L10	16,13	15,39	17,4
L11	16,05	15,43	62
L12	17,38	16,72	133
L13	16,56	15,98	91,6
L14	16,8	16,06	28
L15	16,91	16,2	56,6

L16	17,15	16,28	27,8
L17	17,18	16,58	51,9
L18	17,76	16,94	54,7
L19	16,81	16,09	38,4
L20	17,08	16,27	73,8
L21	16,68	15,86	61,2
L22	16,61	15,98	62,9
L23	16,51	15,9	77,5
L24	16,83	16,03	67,5
L25	16,51	16	57,9
L26	16,6	15,76	50,2
L27	16,48	15,76	44,2
L28	16,68	15,8	46,1
L29	16,75	15,97	150
L30	11,81	11,06	1,12
L31	14,44	13,85	15,2
L32	11	10,42	1,2
L33	8,96	8,1	0,41
L34	14,54	14,01	49,2
L35	14,1	13,47	1,64
L36	8,5	7,77	0,51
L37	15,56	15,06	86,8
L38	15	5,63	5,63

4.2 Contagem visual de pontos

Os resultados obtidos na contagem visual de pontos estão dispostos na tabela 3 (Apêndice B). A porosidade obtida na contagem visual de pontos tem uma diferença média de 17,6% quando comparada àquela obtida por análise de laboratório. Isso se dá porque a contagem visual de pontos é feita em lâmina delgada, que constitui um recorte milimétrico do plugue analisado em laboratório. Ou seja, a contagem de pontos é feita em duas dimensões (2D) e a análise de porosidade em laboratório é feita em três dimensões (3D).

4.3 Porosidade quantificada por inteligência artificial (I.A.)

Os resultados obtidos pela contagem de porosidade realizada pelo modelo de inteligência artificial estão dispostos na tabela 3 (Apêndice B). A porosidade obtida pela I.A. tem uma diferença média de 22,1% quando comparada com os resultados obtidos por análise de laboratório e uma diferença média de 16,04% quando comparada com a contagem visual de pontos. Tanto a contagem visual de pontos quanto a contagem de poros feita pela I.A. foram realizadas em lâminas delgadas e por isso sua comparação tem um fator representativo maior.

A aplicação da correlação linear foi utilizada para melhor visualizar a comparação dos dados obtidos pelas técnicas distintas, conforme figura abaixo (Figura 11). Neste *crossplot*, o eixo X corresponde aos dados de porosidade obtidos pelo modelo de inteligência artificial e no eixo Y estão dispostos os dados de porosidade correspondentes a contagem de pontos visual e os dados de porosidade obtidos em laboratório (do tipo ambiente e tipo NCS).

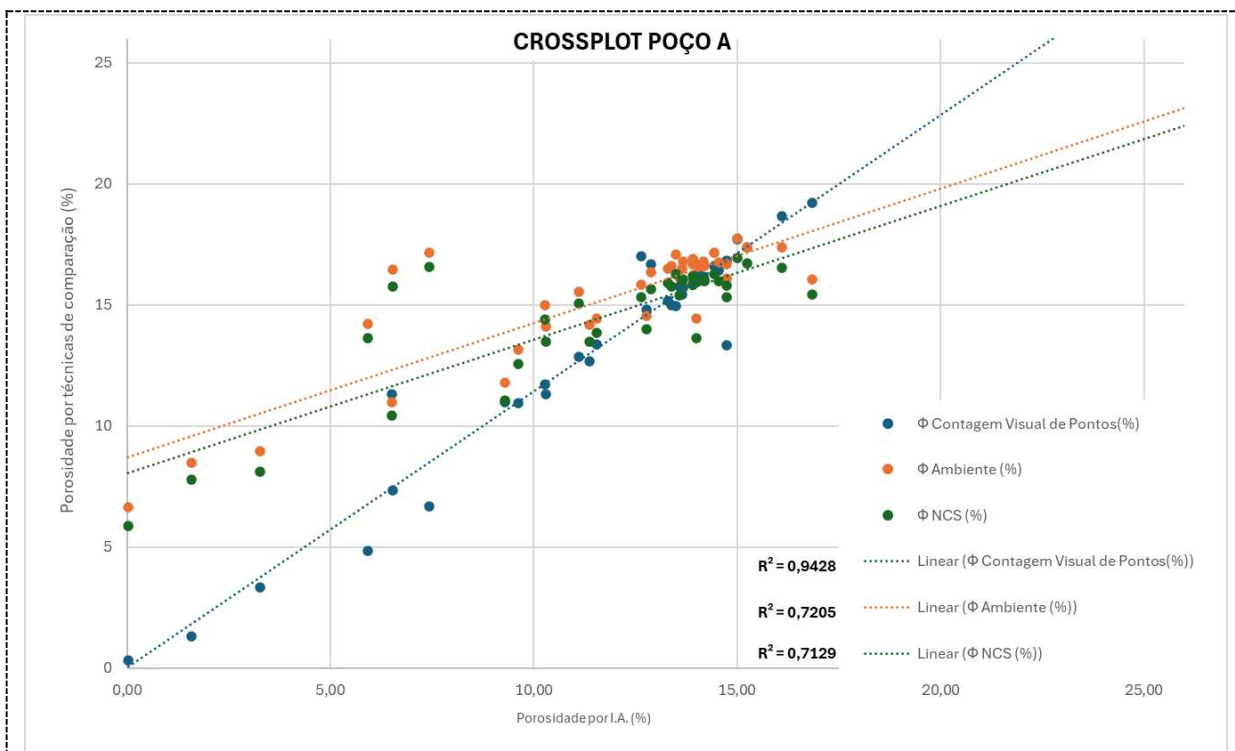


Figura 11 - Gráfico de dispersão mostrando a correlação entre os dados de porosidade obtidos pelas diferentes técnicas utilizadas neste trabalho. O eixo X corresponde aos valores de porosidade obtidos por inteligência artificial e no eixo Y são plotados os valores obtidos pelas outras técnicas. As linhas correspondem a regressões lineares onde o coeficiente de correlação é mostrado ao lado da respectiva linha na legenda da porção inferior direita da imagem.

O coeficiente de determinação (R^2) calculado apresenta uma melhor correlação entre as técnicas que utilizam dados em duas dimensões do que com os dados em três dimensões.

Quanto mais próximos de 1 os valores do coeficiente de determinação, mais ajustado é a técnica de comparação. Para a comparação da contagem de porosidade obtida por inteligência artificial e a porosidade por contagem visual de pontos, o coeficiente de correlação foi de 0,94, evidenciando a representatividade e confiabilidade do uso da ferramenta de inteligência artificial. Quando comparado com os valores obtidos pelas análises de laboratório tipo ambiente e tipo NCS, os coeficientes mostram valores de 0,72 e 0,71. Essa diferença se dá possivelmente pela discrepância de escala nas análises.

4.4 Análise de fácies

Os depósitos da Formação Cabeças são definidos como sistemas deltaicos dominados pela ação de maré, ou seja, ocorrem em regiões afetadas por macromarés (amplitude superior a 4 m) que neutralizam a ação fluvial (Della Fávera, 2001).

Na região estudada, os corpos arenosos descritos correspondem a barras de maré que são corpos arenosos paralelos, alongados na direção da corrente de maré e depositados abaixo do nível de maré baixa.

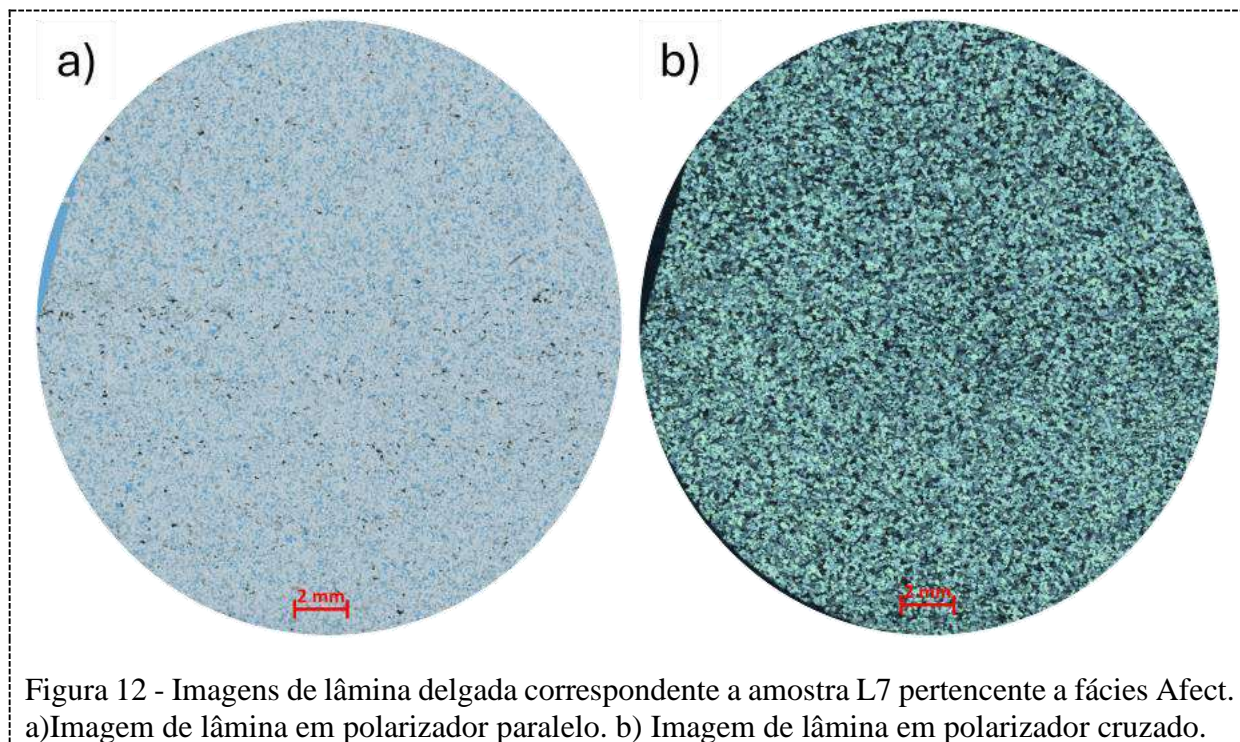
A sucessão vertical progradante apresenta granocrescência ascendente, ou seja, na base ocorrem sedimentos finos de plataforma com estratificação lenticular e ondular de siltitos e arenitos e, em direção ao topo predominam arenitos com estratificação sigmoidal unidirecional, com superfícies de reativação na parte superior, indicativa da progradação da crista da barra (Della Fávera, 2001).

O quadro de fácies foi definido levando em consideração a litologia, textura e estruturas sedimentares. As fácies Amfec (Arenito muito fino com estratificação cruzada cavalgante), AmfM (Arenito muito fino maciço) e Afect (Arenito fino com estratificação cruzada tabular) representam a maioria das fácies reservatório observadas no testemunho e no conjunto de lâminas delgadas provenientes de plugues de testemunho disponíveis e por isso foram escolhidas para o estudo de detalhe. Essas fácies correspondem a arenitos muito finos e finos depositados por correntes em meio subaquoso.

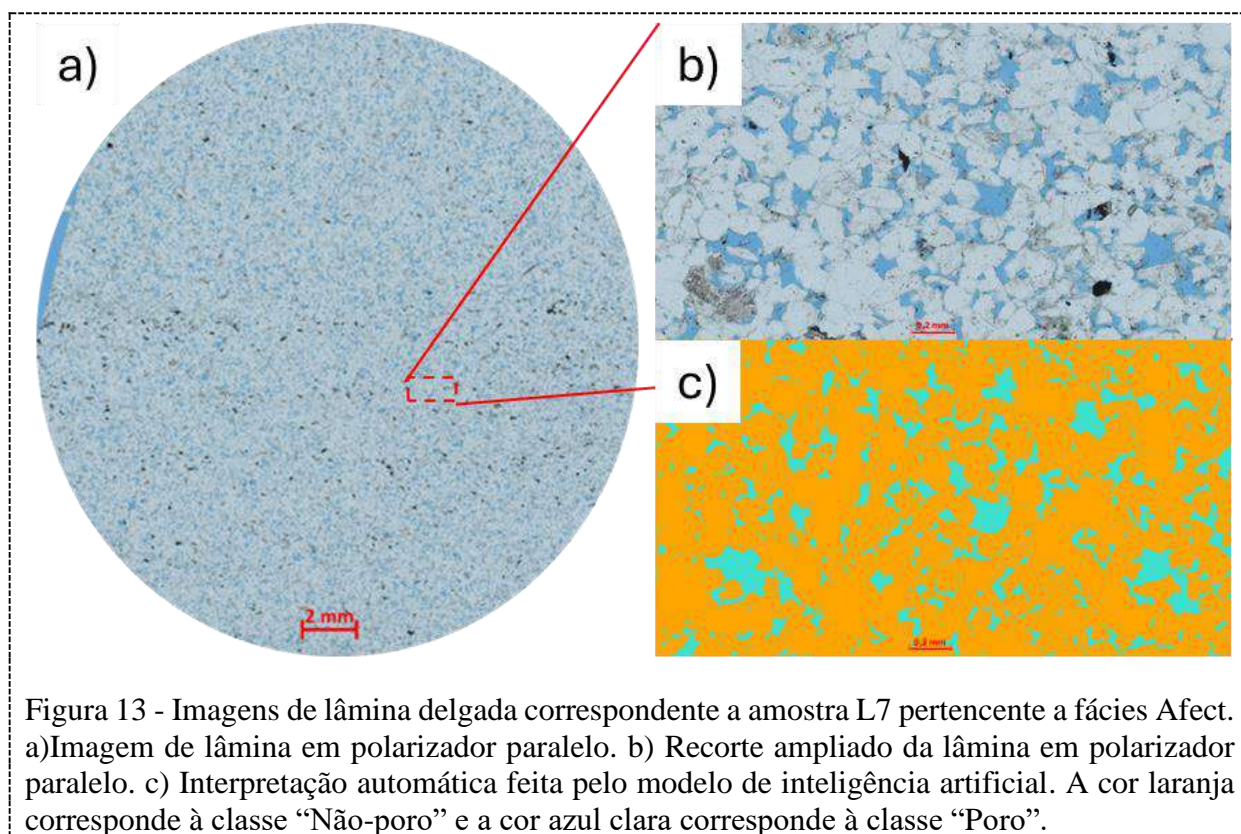
4.4.1 Afect (Arenito fino com estratificação cruzada tabular)

Esta fácies foi descrita como arenito fino, subarcóseo, bem selecionado, bege claro, com estratificações cruzadas tabulares por vezes incipientes. A rocha possui empacotamento moderado e é composta por grãos subarredondados de quartzo, feldspato, argilominerais, minerais pesados (grãos de zircão), óxidos e sulfetos (pirita). *Climbing ripples* de maré são comuns. Como eventos e constituintes diagenéticos observa-se sobrecrescimento de quartzo e dissolução de feldspatos, pirita e óxido como substituição, cimentação por carbonatos, cutículas de illita e ilitização de grãos. A porosidade do tipo intergranular é predominante.

Na análise semiquantitativa foi identificado nesta lâmina delgada (Figura 12), 80,67% dos pontos classificados como de grãos de quartzo, arredondados a sub-arredondados e ocasionalmente grãos de feldspatos alterados por diagênese; 3,3% correspondente a minerais pesados e óxidos opacos; 2,67% de argilas (ilitas e esmectitas) preenchendo os espaços intergranulares; e 13,33% de poros predominantemente intergranulares.




O modelo de inteligência artificial inferiu nesta imagem de lâmina delgada 14,75% de espaço poroso (Figura 13). Este resultado representa uma diferença de 10,65% quando comparado com o resultado de contagem de pontos e uma diferença de 8,3% quando comparado com o resultado obtido em laboratório.



4.4.2 Amfec (Arenito muito fino com estratificação cruzada cavalgante)

Esta fácies foi descrita como arenito fino, subarcóseo, bem selecionado, bege claro, com estratificações cruzadas cavalgantes por vezes insipientes. A rocha possui empacotamento moderado e é composta por grãos subarredondados de quartzo, feldspato, argilominerais, minerais pesados (grãos de zircão), óxidos e sulfetos (pirita). *Climbing ripples* de maré são comuns. Como eventos e constituintes diagenéticos observa-se sobrecrescimento de quartzo e dissolução de feldspatos, pirita e óxido como substituição, cimentação por carbonatos, cutículas de illita e ilitização de grãos. A porosidade intergranular é predominante.

Na análise semiquantitativa foi identificado nesta lâmina delgada (Figura 14), 68,0% dos pontos analisados como grãos predominantemente de grãos de quartzo, arredondados a sub-arredondados e ocasionalmente grãos de feldspatos alterados por diagênese, 3,5% correspondente a minerais pesados e óxidos opacos, 8,67% de argilas (illitas e esmectitas) preenchendo os espaços intergranulares, 7,34% correspondem a cimento diagenético (dissolução e crescimento de sílica) e 12,67% de poros predominantemente intergranulares.



O modelo de inteligência artificial inferiu nesta imagem de lâmina delgada (Figura 15) 12,77% de espaço poroso. Este resultado representa uma diferença de 13,79% quando comparado com o resultado de contagem de pontos e uma diferença de 12,1% quando comparado com o resultado obtido em laboratório.

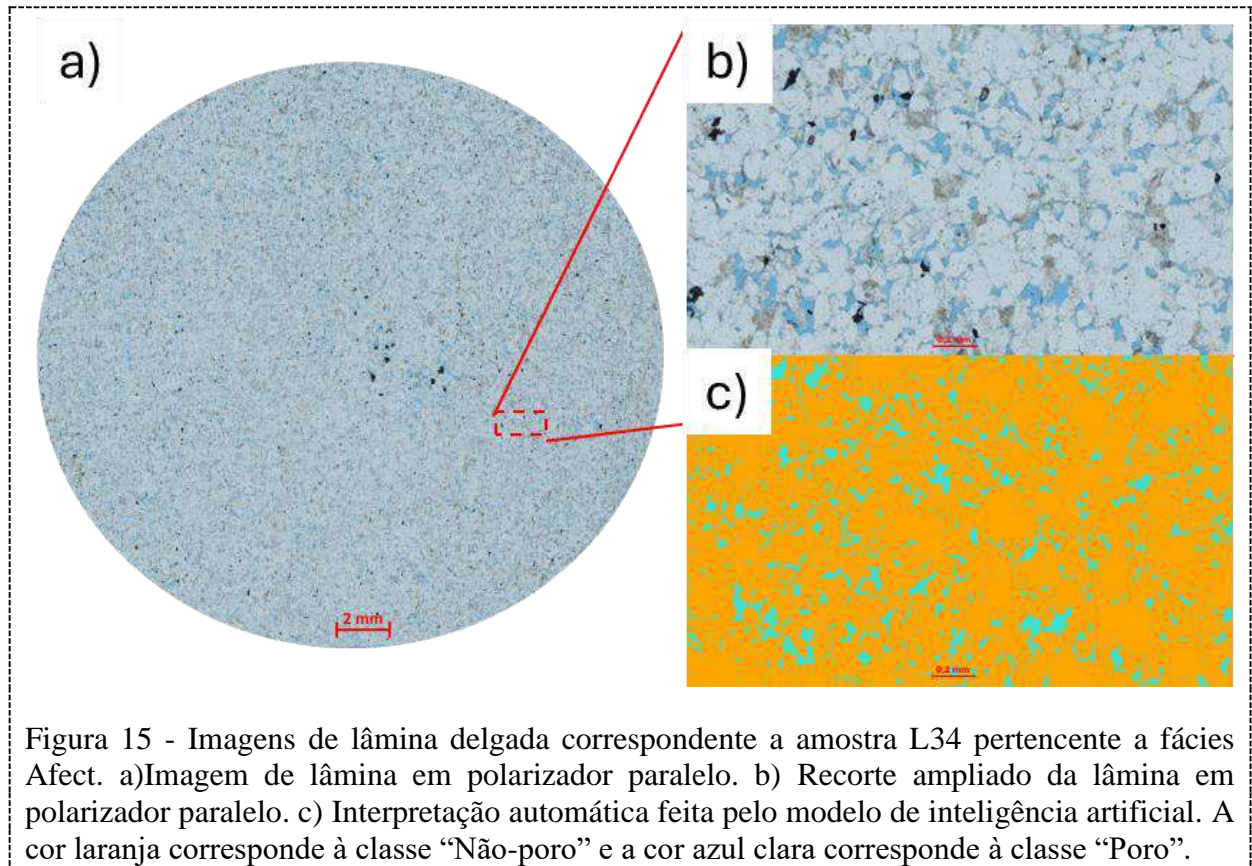
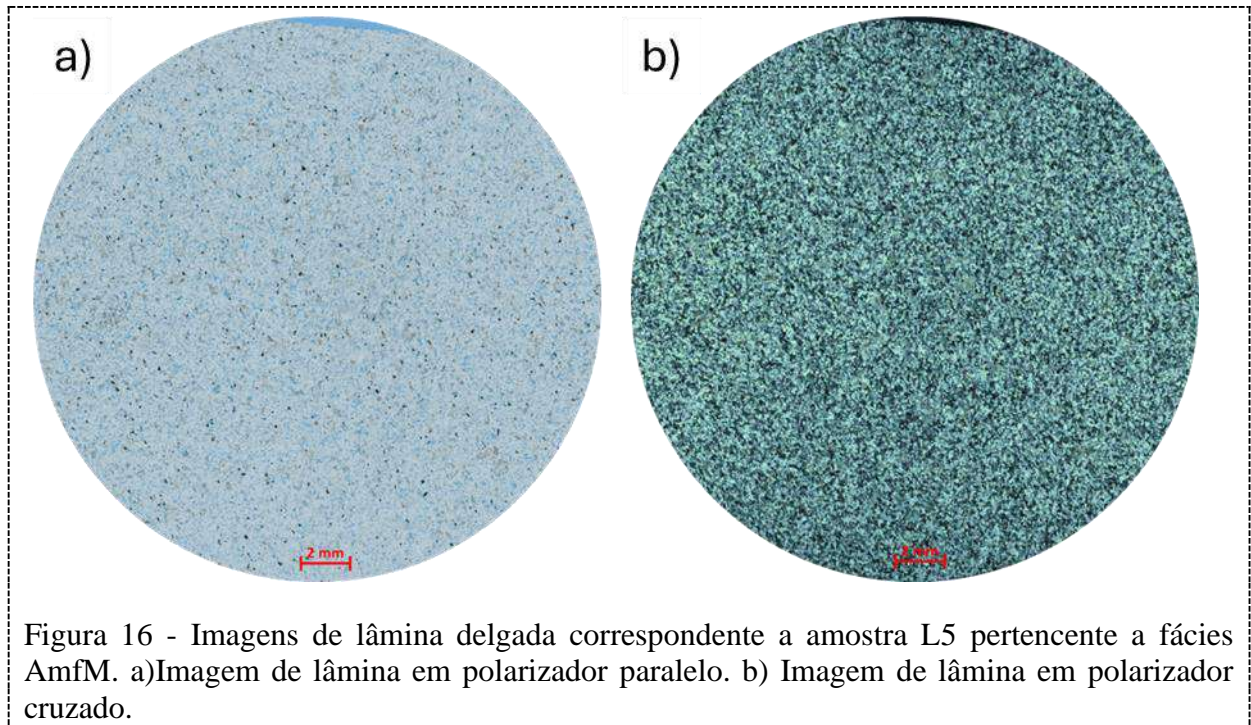


Figura 15 - Imagens de lâmina delgada correspondente a amostra L34 pertencente a fácies Afect. a) Imagem de lâmina em polarizador paralelo. b) Recorte ampliado da lâmina em polarizador paralelo. c) Interpretação automática feita pelo modelo de inteligência artificial. A cor laranja corresponde à classe “Não-poro” e a cor azul clara corresponde à classe “Poro”.

4.4.3 AmfM (Arenito muito fino maciço)

Esta fácies foi descrita como arenito fino, subarcóseo, bem selecionado, bege claro, estrutura maciça. A rocha possui empacotamento moderado e é composta por grãos subarredondados de quartzo, feldspato, argilominerais, minerais pesados (grãos de zircão), óxidos e sulfetos (pirita). Como eventos e constituintes diagenéticos observa-se sobrecrescimento de quartzo e dissolução de feldspatos, pirita e óxido como substituição, cimentação por carbonatos e anidrita, cutículas de illita e illitização de grãos. A porosidade intergranular é predominante.

Na análise semiquantitativa foi identificado nesta lâmina delgada (Figura 16), 65,33% dos pontos analisados como grãos predominantemente de grãos de quartzo, arredondados a subarredondados e grãos de feldspatos ocasionalmente alterados por diagênese, 4,75% correspondente a minerais pesados e óxidos opacos, 7,56% de argilas (illitas e esmectitas) preenchendo os espaços intergranulares, 6,74% correspondem a cimento diagenético (dissolução e crescimento de sílica) e 15,85% de poros predominantemente intergranulares.



O modelo de inteligência artificial nesta imagem de lâmina delgada (Figura 17) inferiu 13,91% de espaço poroso. Este resultado representa uma diferença de 12,28% quando comparado com o resultado de contagem de pontos e uma diferença de 16,6% quando comparado com o resultado obtido em laboratório.

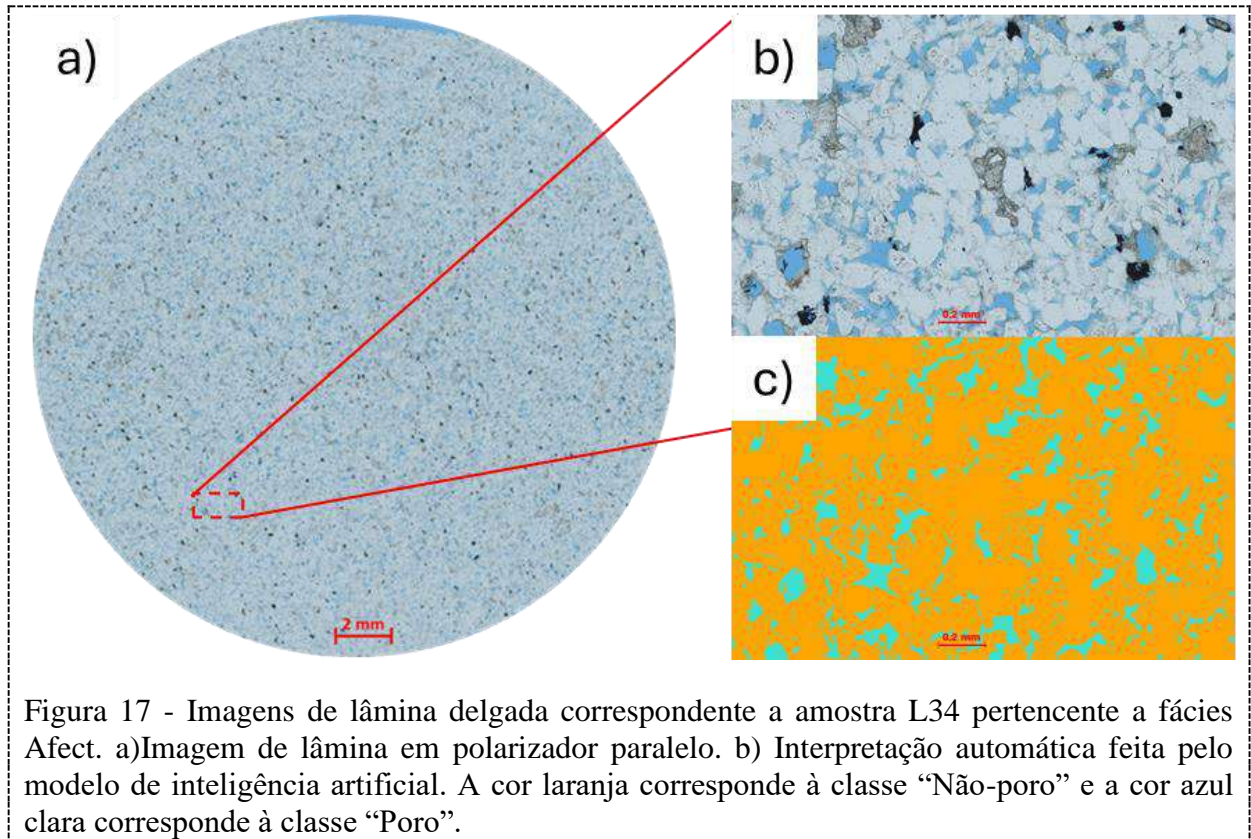
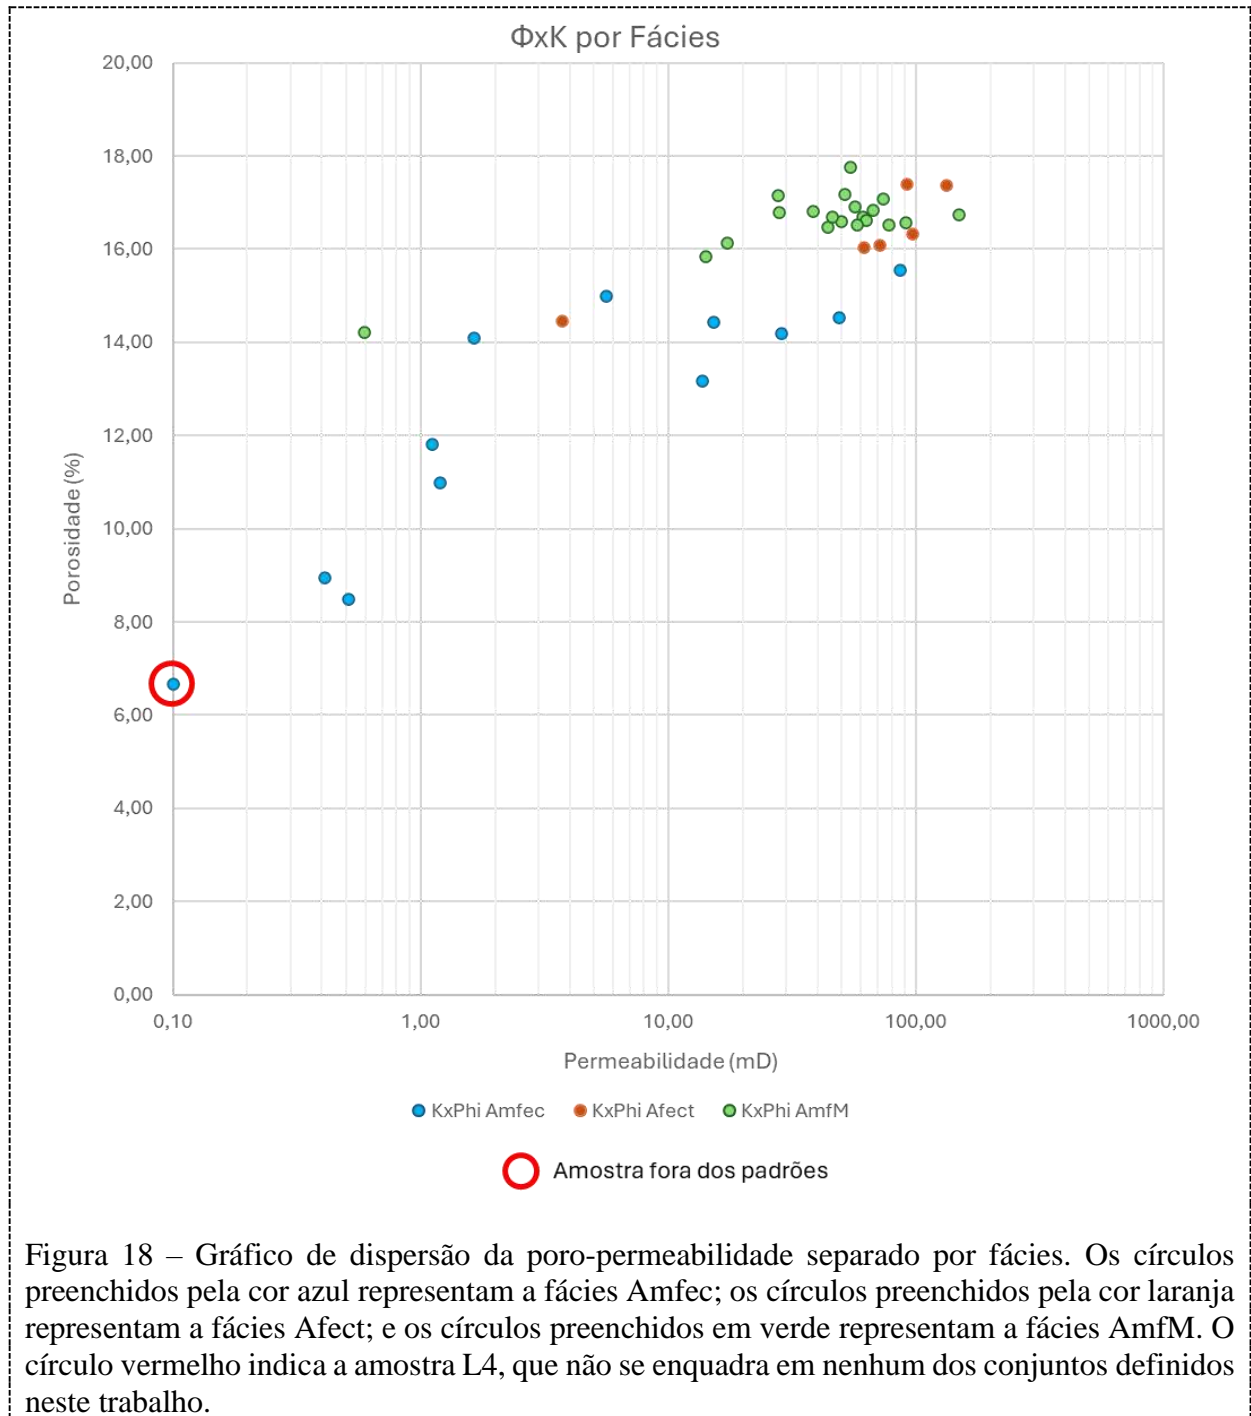


Figura 17 - Imagens de lâmina delgada correspondente a amostra L34 pertencente a fácies Afect. a) Imagem de lâmina em polarizador paralelo. b) Interpretação automática feita pelo modelo de inteligência artificial. A cor laranja corresponde à classe “Não-poro” e a cor azul clara corresponde à classe “Poro”.

Os conjuntos de lâminas foram definidos a partir da descrição e observação das 38 lâminas delgadas pertencentes às 3 fácies que representam o principal reservatório da Formação Cabeças no poço descrito: AmfM(Arenito muito fino maciço), Afect(Arenito fino com estratificação cruzada tabular) e Amfec(Arenito muito fino com estratificação cruzada cavalgante).

A porosidade e permeabilidade obtidas em laboratório foram plotadas em um gráfico de dispersão (Figura 18). Foram definidos conjuntos a partir do método estatístico *K-means* e reconhecidos 3 grupos principais de características permo-porosas distintas chamados nesse trabalho de “conjuntos”.



4.4.4 Amostra fora dos padrões:

A amostra L4 foi considerada como uma disparidade do espaço amostral pois não se enquadra nos conjuntos definidos mesmo havendo heterogeneidades nestes grupos. O espaço poroso da amostra L4 (Figura 19) encontra-se completamente preenchido por argilas(caulinita?), obliterando os poros intergranulares.

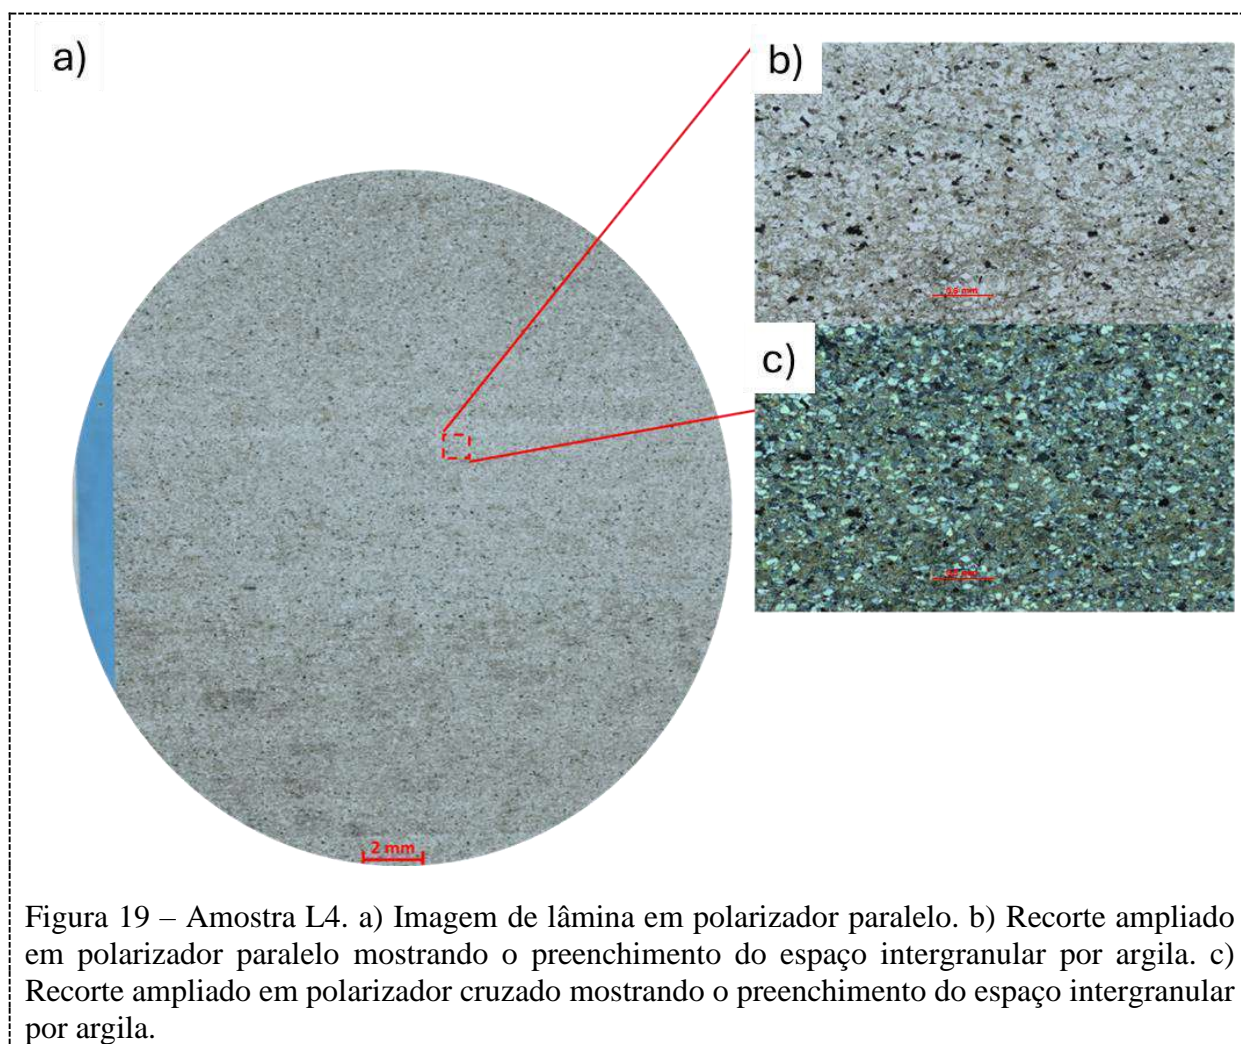


Figura 19 – Amostra L4. a) Imagem de lâmina em polarizador paralelo. b) Recorte ampliado em polarizador paralelo mostrando o preenchimento do espaço intergranular por argila. c) Recorte ampliado em polarizador cruzado mostrando o preenchimento do espaço intergranular por argila.

Para a utilização do método estatístico K-means e definição dos conjuntos foram escolhidos os dados de porosidade e permeabilidade normalizados, mostrados no gráfico a seguir (Figura 20). Os conjuntos definidos apresentam baixa, média e boa permo-porosidade. Mesmo dentro desses conjuntos são observadas algumas heterogeneidades explicadas caso a caso a seguir.

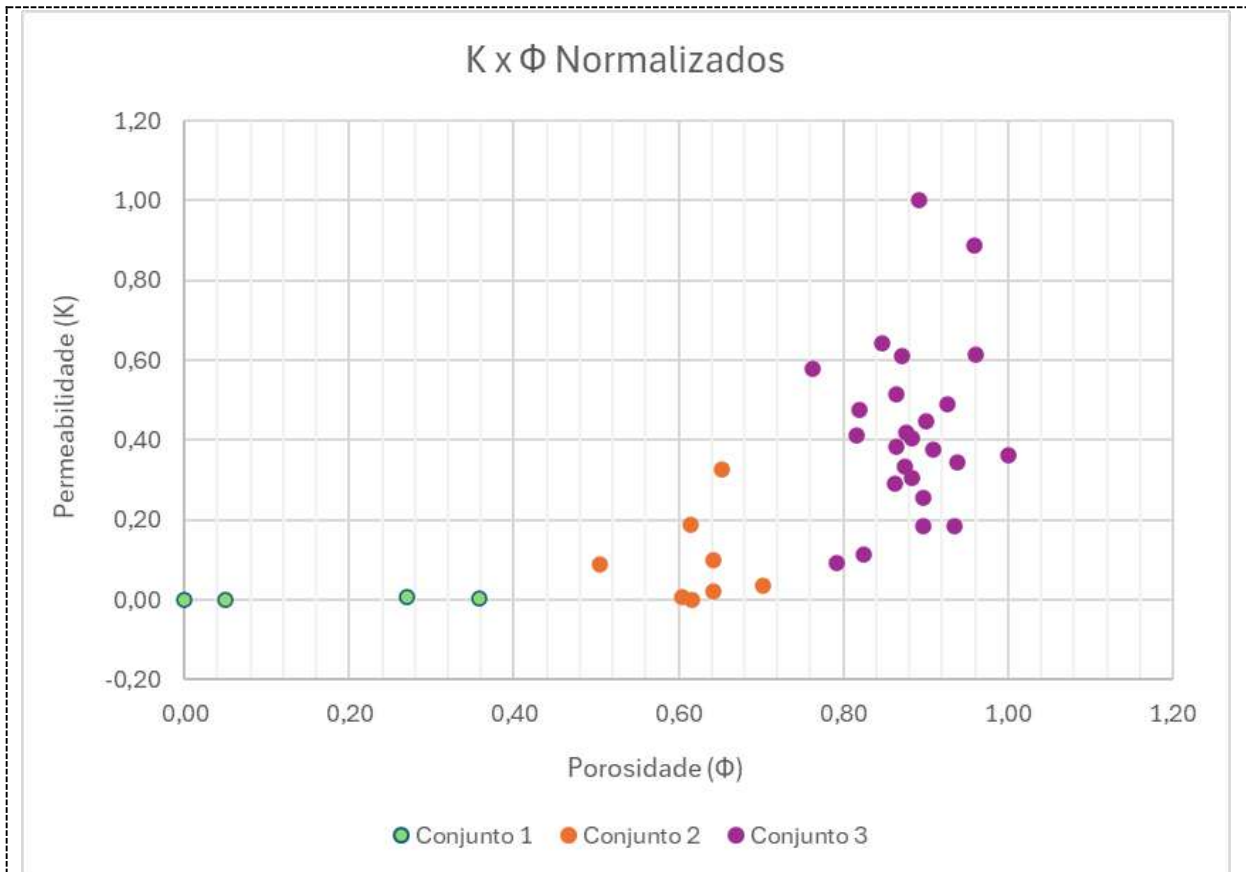
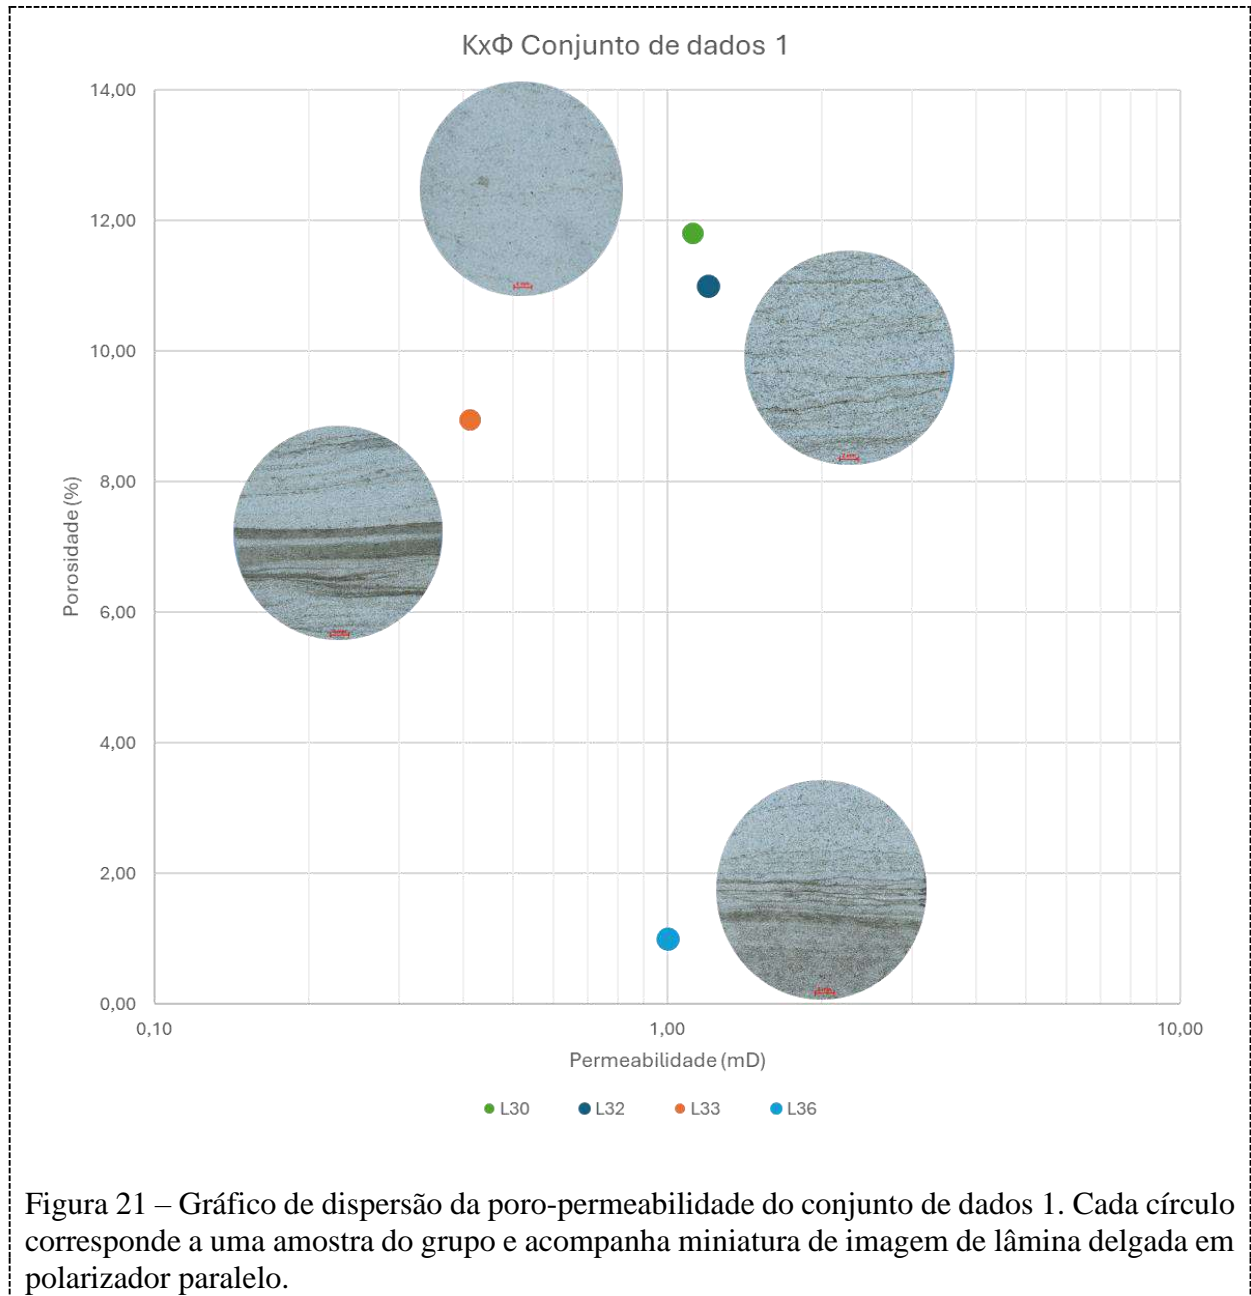


Figura 20 – Gráfico de dispersão da poro-permeabilidade das amostras normalizado. O eixo X representa os dados de porosidade e o eixo Y representa os dados de permeabilidade. As cores representam os diferentes conjuntos em que foram divididas as amostras.

4.4.5 Conjunto de dados 1:

O conjunto 1 (Figura 21) é composto por 4 amostras(L30, L31, L32 e L33) que possuem baixa poro-permeabilidade, reconhecidas pela quantidade de argila disposta de forma laminada, fator prejudicial para a porosidade visual e permeabilidade da rocha. Elas pertencem a fácies Amfec e estão inseridas num contexto um pouco mais lamoso das barras de maré. A amostra L30 é diferente das demais, pois possui laminação menos preservada, incipiente. Isso se dá pois esta amostra é proveniente de uma porção mais arenosa da barra de maré.

Para este conjunto, o modelo de inteligência artificial apresentou dificuldades de reconhecimento dos poros da rocha devido a presença de argila intergranular.



4.4.6 Conjunto de dados 2:

O conjunto 2 possui as amostras L1, L2, L6, L8, L31, L34, L35 e L38. Diferente do conjunto 1, nem todas as amostras pertencem a mesma fácies. A amostra L8 pertence a fácies Afect, ou seja, é um arenito de granulometria fina e as amostras L35 e L38 são de arenitos com granulometria muito fina. Neste conjunto, as amostras possuem abundância de feldspatos e pouco conteúdo de argila que ocorre eventualmente de forma laminada no espaço intergranular. A amostra L8, de granulometria fina, possui intraclastos argilosos que interfere nos resultados de porosidade e permeabilidade da rocha. Os feldspatos exibem feições de dissolução que geram porosidade intragranular, contribuindo para uma porosidade melhor quando comparada com o conjunto 1 (Figura 22).

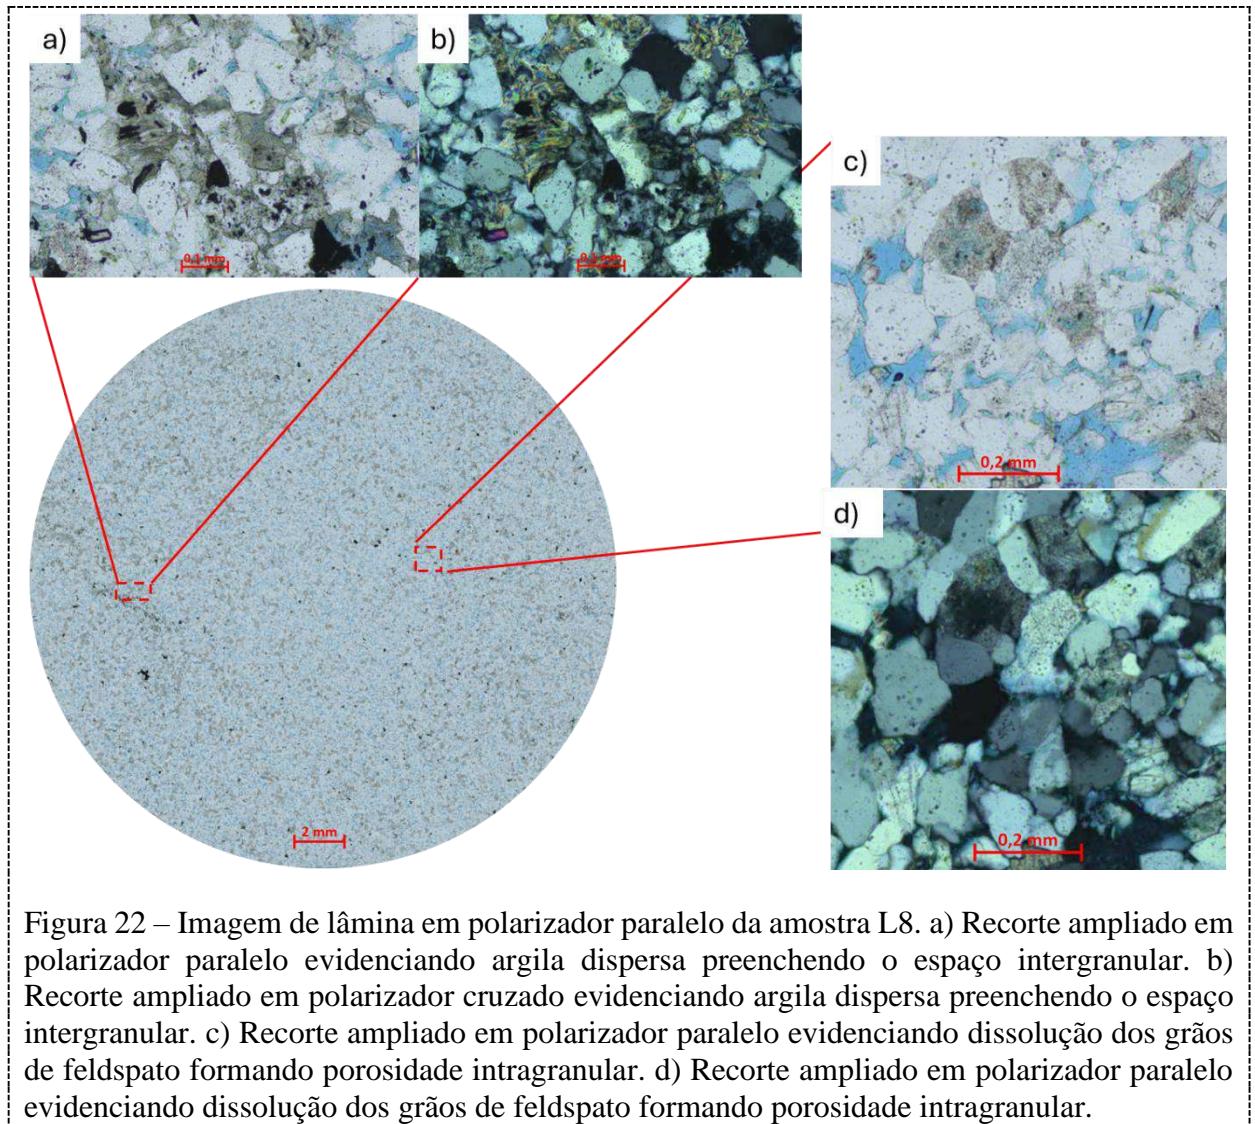


Figura 22 – Imagem de lâmina em polarizador paralelo da amostra L8. a) Recorte ampliado em polarizador paralelo evidenciando argila dispersa preenchendo o espaço intergranular. b) Recorte ampliado em polarizador cruzado evidenciando argila dispersa preenchendo o espaço intergranular. c) Recorte ampliado em polarizador paralelo evidenciando dissolução dos grãos de feldspato formando porosidade intragranular. d) Recorte ampliado em polarizador paralelo evidenciando dissolução dos grãos de feldspato formando porosidade intragranular.

4.4.7 Conjunto de dados 3

O conjunto 3 é formado pelas amostras: L3, L5, L7, L9, L10, L11, L12, L13, L14, L15, L16, L17, L18, L19, L20, L21, L22, L23, L24, L25, L26, L27, L28, L29 e L37. Estas amostras correspondem a associação de fácies de canais de maré (Figura 23). Esta associação de fácies apresenta pouco conteúdo argiloso e depositam feições arenosas delgadas com boa disposição do sistema poroso.




Figura 23 – Perfil sedimentológico evidenciando a associação de fácies de canais de maré.

As amostras deste conjunto possuem pouca argila intergranular, abundância de óxidos e minerais pesados dispersos nas amostras e por vezes aparecem cristais de anidrita, principalmente nas amostras L27 e L10 (Figura 24).

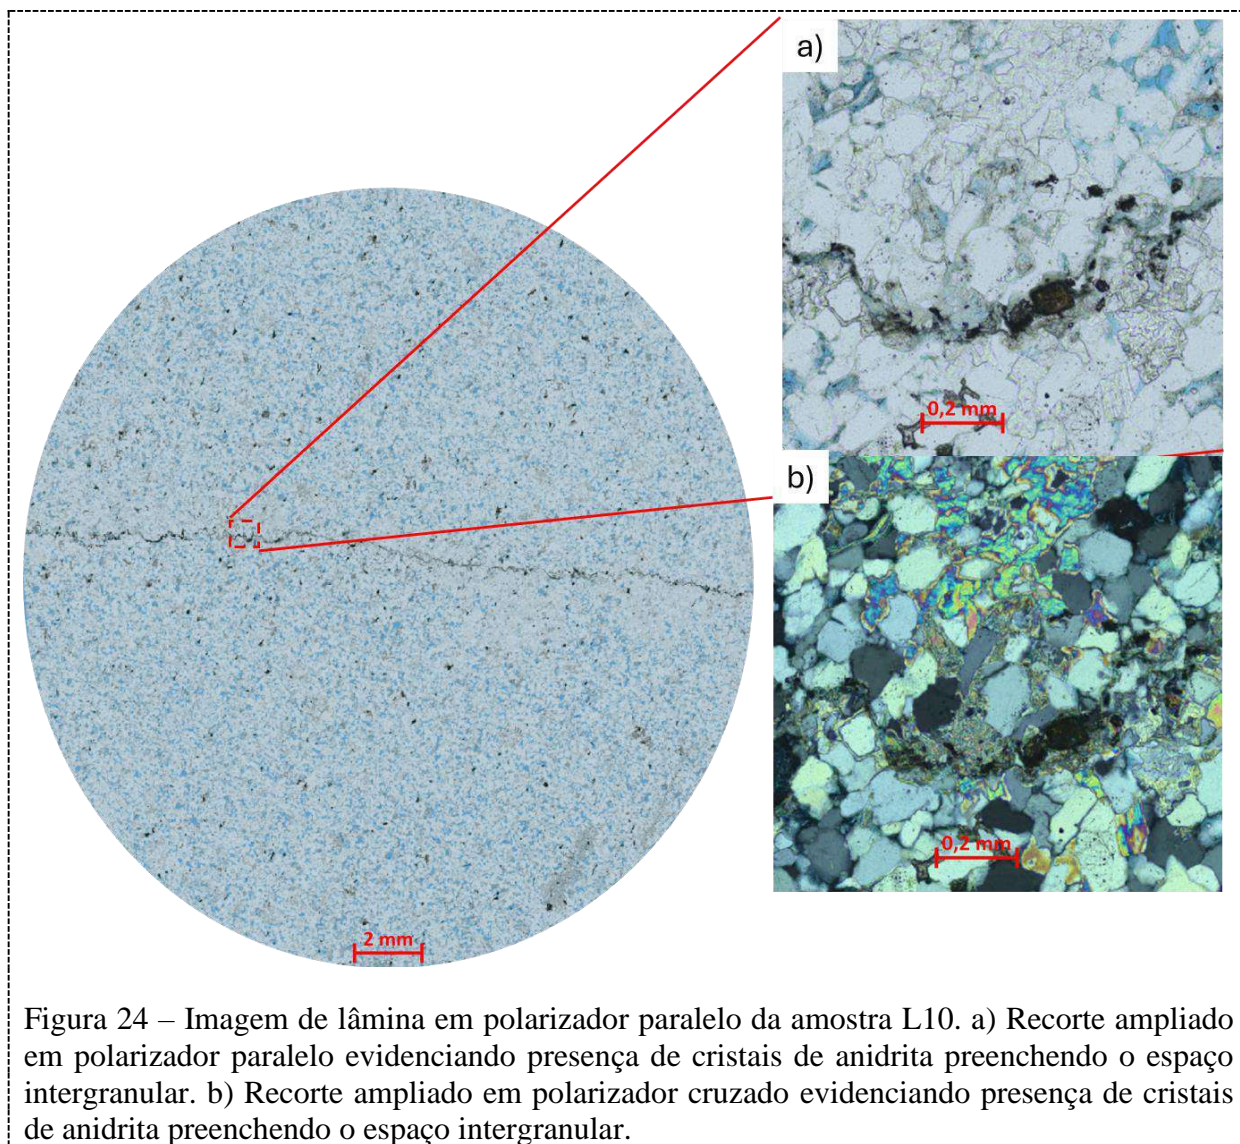


Figura 24 – Imagem de lâmina em polarizador paralelo da amostra L10. a) Recorte ampliado em polarizador paralelo evidenciando presença de cristais de anidrita preenchendo o espaço intergranular. b) Recorte ampliado em polarizador cruzado evidenciando presença de cristais de anidrita preenchendo o espaço intergranular.

Este conjunto é o que apresenta as melhores características permo-porosas e que apresenta melhor correlação com os dados inferidos pelo modelo de inteligência artificial utilizado neste estudo.

5 CONCLUSÃO

A aplicação da inteligência artificial para o cálculo automatizado da porosidade se mostrou uma ferramenta promissora na caracterização de reservatórios, permitindo a análise rápida e objetiva de um grande volume de dados. O método demonstrou potencial para auxiliar na seleção de intervalos produtivos e otimizar a avaliação de intervalos reservatório, contribuindo para a eficiência na exploração de gás natural na Bacia do Parnaíba.

Os resultados obtidos no estudo das fácies da Formação Cabeças indicam que os depósitos analisados representam um sistema de barras de maré e canais de maré, caracterizado pela predominância de arenitos finos a muito finos. As principais fácies reservatório escolhidas para este trabalho apresentaram variações significativas em termos de porosidade e permeabilidade, influenciadas pela presença de argilas, óxidos e cimentação carbonática.

A análise petrográfica das lâminas delgadas revelou que a porosidade predominante é intergranular, com variações locais associadas à dissolução de feldspatos e ao preenchimento por argilas. A contagem visual de pontos indicou diferenças médias de 17,6% em relação às medições laboratoriais de porosidade, refletindo a complexidade na quantificação desse parâmetro em diferentes escalas. Os dados de petrofísica básica de laboratório mostraram que a porosidade das amostras varia de 6,66% a 17,76%, enquanto a permeabilidade variou entre 0,1 e 150 mD.

A análise estatística pelo método *K-means* permitiu a definição de três conjuntos de dados principais de características permo-porosas distintas, sendo o conjunto de dados 3, associado às fácies de canais de maré, aquele com melhor potencial como reservatório de gás.

O modelo de inteligência artificial aplicado à quantificação da porosidade demonstrou boa correlação com os métodos convencionais, especialmente com a contagem visual de pontos.

Entretanto, a comparação entre os resultados obtidos pelas diferentes técnicas indicou que o modelo de inteligência artificial apresenta limitações em contextos onde há alta presença de argilas preenchendo os espaços porosos. Nestes casos, a identificação automática pode ser comprometida, sendo necessária a calibração do modelo ou o uso de técnicas complementares para refinar os resultados. Além disso, o uso de inteligência artificial para quantificação de porosidade abre possibilidades para o desenvolvimento de algoritmos mais sofisticados capazes de diferenciar melhor os tipos de porosidade, características texturais das rochas e a influência de processos diagenéticos. A continuidade dessa linha de pesquisa pode levar à criação de modelos preditivos mais precisos, integrando dados de petrofísica, imagens de lâminas e outras técnicas de investigação para aprimorar a caracterização de reservatórios.

Por fim, a automação de processos como a análise de lâminas delgadas e a quantificação de porosidade representa um avanço significativo para a indústria, reduzindo o tempo de análise, minimizando erros humanos e aumentando a confiabilidade dos dados, elementos fundamentais para o sucesso da exploração de hidrocarbonetos, principalmente no contexto de segurança energética visando evitar a dependência hídrica do sistema energético brasileiro.

Apêndice A

Tabela 1 — Código das lâminas delgadas utilizadas neste estudo com as respectivas profundidades e fácies sedimentares de onde foram extraídas.

Código	Profundidade	Fácies	Associação de Fácies
L1	1600,9	Amfec	Shoreface inferior (inframaré)
L2	1601,21	Amfec	Shoreface inferior (inframaré)
L3	1601,52	Afect	Barras de maré
L4	1602,88	Amfec	Barras de maré (Inframaré)
L5	1603,13	AmfM	Barras de maré
L6	1603,9	AmfM	Intermaré
L7	1604,67	Afect	Barras de maré
L8	1604,9	Afect	Barras de maré
L9	1605	Afect	Barras de maré
L10	1605,6	AmfM	Barras de maré
L11	1605,9	Afect	Barras de maré
L12	1605,92	Afect	Barras de maré
L13	1606,5	AmfM	Canais de maré
L14	1606,9	AmfM	Canais de maré
L15	1607,1	AmfM	Canais de maré
L16	1607,74	AmfM	Canais de maré
L17	1608,86	AmfM	Canais de maré
L18	1609,18	AmfM	Canais de maré

L19	1609,48	AmfM	Canais de maré
L20	1609,86	AmfM	Canais de maré
L21	1610,38	AmfM	Canais de maré
L22	1610,68	AmfM	Canais de maré
L23	1610,86	AmfM	Canais de maré
L24	1610,98	AmfM	Canais de maré
L25	1611,28	AmfM	Canais de maré
L26	1611,58	AmfM	Canais de maré
L27	1611,9	AmfM	Canais de maré
L28	1611,92	AmfM	Canais de maré
L29	1612,2	AmfM	Canais de maré
L30	1614,86	Amfec	Shoreface médio (inframaré)
L31	1615,85	Amfec	Barras de maré
L32	1615,96	Amfec	Barras de maré
L33	1616,26	Amfec	Shoreface médio (inframaré)
L34	1616,56	Amfec	Shoreface médio (inframaré)
L35	1617,16	Amfec	Shoreface médio (inframaré)
L36	1617,49	Amfec	Barras de maré
L37	1617,79	Amfec	Shoreface médio (inframaré)
L38	1617,84	Amfec	Shoreface médio (inframaré)

Apêndice B

Tabela 3 – Código das lâminas delgadas utilizadas neste estudo com as respectivas medidas obtidas na contagem de 300 pontos e no modelo de inteligência artificial.

Código	Porosidade obtida na contagem de 300 pontos (%)	Porosidade obtida por inteligência artificial (%)
L1	10,96	9,61
L2	12,67	11,38
L3	16,67	12,89
L4	0,33	0,03
L5	17	12,63
L6	4,85	5,92
L7	13,33	14,75
L8	15,95	13,99
L9	18,68	16,1
L10	15,76	13,59
L11	19,21	16,85
L12	17,39	15,25
L13	16,33	14,03
L14	15,72	13,67
L15	15,85	13,9
L16	16,61	14,44
L17	6,67	7,43
L18	17,71	15,01

L19	16,17	14,18
L20	14,97	13,49
L21	15,86	13,91
L22	16,03	14,19
L23	15,16	13,3
L24	16,03	13,94
L25	15,42	13,65
L26	15	13,39
L27	7,33	6,52
L28	16,82	14,75
L29	16,44	14,55
L30	10,97	9,3
L31	13,39	11,54
L32	11,33	6,5
L33	3,33	3,26
L34	14,81	12,77
L35	11,33	10,3
L36	1,33	1,59
L37	12,88	11,1
L38	11,71	10,27

Referências bibliográficas

- Allen, P. A., & Allen, J. R. (2013). *Basin Analysis: Principles and Applications*. Wiley-Blackwell.
- Bjørlykke, K. (2010). *Petroleum Geoscience: From Sedimentary Environments to Rock Physics*. Springer.
- Caputo, M. V. (1984). Paleoclimatic and paleogeographic significance of glacial deposits of the Late Ordovician–Early Silurian age in Brazil. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 45(1-2), 133-152.
- Caputo, M. V., & Lima, M. R. (1984). The Devonian–Carboniferous succession of the Parnaíba Basin. *Brazilian Journal of Geology*, 14(3), 127-144.
- Della Fávera, J. C. (2001). *Estratigrafia de sequências e eventos deposicionais nas bacias sedimentares brasileiras*. Editora Interciência.
- EPE – Empresa de Pesquisa Energética. (2023). *Plano Decenal de Expansão de Energia 2032*. Brasília.
- Freitas, J. E. (1990). Tectônica e sedimentação da Bacia do Parnaíba. *Revista Brasileira de Geociências*, 20(1), 31-43.
- Góes, A. M., & Feijó, F. J. (1994). Bacia do Parnaíba. *Boletim de Geociências da Petrobras*, 8(1), 57-72.
- International Energy Agency (IEA). (2023). *World Energy Outlook 2023*. Paris.
- Intergovernmental Panel on Climate Change (IPCC). (2022). *Climate Change 2022: Mitigation of Climate Change*. Cambridge University Press.
- Jahn, F., Cook, M., & Graham, M. (2008). *Hydrocarbon Exploration and Production*. Elsevier.
- Netto, L. S. A. (2024). *Mercado de Carbono no Brasil: Impactos Esperados da Adoção de Instrumento Econômico Regulado para Redução de Emissões no Setor Elétrico Nacional*. Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Instituto de Economia, Programa de Pós-Graduação em Políticas Públicas, Estratégias e Desenvolvimento.
- Rodrigues, R. (1995). Potencial hidrocarbonífero da Bacia do Parnaíba. *Boletim Técnico da Petrobras*, 38(3), 211-229.
- Tucker, M. E. (2001). *Petrology of Sedimentary Rocks*. Wiley-Blackwell.
- Vaz, P. B. (2007). Evolução tectônica e sedimentar da Bacia do Parnaíba. *Revista Brasileira de Geociências*, 37(4), 633-646.