



UNIVERSIDADE ESTADUAL DE CAMPINAS
Instituto de Geociências

FABIAN ANDRES PAEZ SARMIENTO

IDENTIFICAÇÃO DE UNIDADES DE FLUXO NA FORMAÇÃO BARRA VELHA DO
PRÉ-SAL BRASILEIRO E SUA RELAÇÃO COM ELETROFÁCIES E PETROFÁCIES
FEITAS ATRAVÉS DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

CAMPINAS

2022

FABIAN ANDRES PAEZ SARMIENTO

IDENTIFICAÇÃO DE UNIDADES DE FLUXO NA FORMAÇÃO BARRA VELHA DO
PRÉ-SAL BRASILEIRO E SUA RELAÇÃO COM ELETROFÁCIES E PETROFÁCIES
FEITAS ATRAVÉS DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

DISSERTAÇÃO APRESENTADA AO INSTITUTO DE
GEOCIÊNCIAS DA UNIVERSIDADE ESTADUAL DE
CAMPINAS PARA OBTENÇÃO DO TÍTULO DE MESTRE
EM GEOCIÊNCIAS NA ÁREA DE GEOLOGIA E
RECURSOS NATURAIS

ORIENTADOR: PROF. DR. ALESSANDRO BATEZELLI

COORIENTADOR: LEIDY ALEXANDRA DELGADO BLANCO

ESTE EXEMPLAR CORRESPONDE À VERSÃO
FINAL DA DISSERTAÇÃO DEFENDIDA PELO
ALUNO FABIAN ANDRES PAEZ SARMIENTO
E ORIENTADA PELO PROF. DR. ALESSANDRO
BATEZELLI

CAMPINAS

2022

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca do Instituto de Geociências
Marta dos Santos - CRB 8/5892

P139i Paez Sarmiento, Fabian Andres, 1996-
Identificação de unidades de fluxo na formação Barra Velha do pré-sal brasileiro e sua relação com eletrofácies e petrofácies feitas através de algoritmos de aprendizagem de máquina / Fabian Andres Paez Sarmiento. – Campinas, SP : [s.n.], 2022.

Orientador: Alessandro Batezelli.

Coorientador: Leidy Alexandra Delgado Blanco.

Dissertação (mestrado) – Universidade Estadual de Campinas, Instituto de Geociências.

1. Pré-sal - Brasil. 2. Carbonatos. 3. Eletrofácies. 4. Petrofísica. 5. Aprendizado de máquina. I. Batezelli, Alessandro, 1972-. II. Delgado Blanco, Leidy Alexandra, 1990-. III. Universidade Estadual de Campinas. Instituto de Geociências. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Identification of flow units in the Barra Velha formation of the brazilian pre-salt and their relationship with electrofacies and petrofacies made through machine learning algorithms

Palavras-chave em inglês:

Pre-salt - Brazil

Carbonates

Electrofacies

Petrophysics

Machine Learning

Área de concentração: Geologia e Recursos Naturais

Titulação: Mestre em Geociências

Banca examinadora:

Alessandro Batezelli [Orientador]

Nathalia Helena Secol Mattos

Francisco Manoel Wohnrath Tognoli

Data de defesa: 01-08-2022

Programa de Pós-Graduação: Geociências

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0003-0230-9733>

- Currículo Lattes do autor: <http://lattes.cnpq.br/3939063450724647>



UNICAMP

**UNIVERSIDADE ESTADUAL DE CAMPINAS
INSTITUTO DE GEOCIÊNCIAS**

AUTOR: Fabian Andres Paez Sarmiento

IDENTIFICAÇÃO DE UNIDADES DE FLUXO NA FORMAÇÃO BARRA VELHA DO PRÉ-SAL BRASILEIRO E SUA RELAÇÃO COM ELETROFÁCIES E PETROFÁCIES FEITAS ATRAVÉS DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

ORIENTADORA: Prof. Dr. Alessandro Batezelli

Aprovado em: 01/08/2022

EXAMINADORES:

Prof. Dr. Alessandro Batezelli - Presidente

Profa. Dra. Nathalia Helena Secl Mattos

Prof. Dr. Francisco Manoel Wohnrath Tognoli

A Ata de Defesa assinada pelos membros da Comissão Examinadora consta no processo de vida acadêmica do aluno.

Campinas, 01 de agosto de 2022.

SÚMULA/BIOGRAFIA

Fabian Andres Paez Sarmiento

Engenheiro de Petróleos (2019), formado pela Universidade Industrial de Santander (UIS) em Bucaramanga – Colômbia, onde desenvolveu um trabalho de conclusão de curso focado no estudo de recuperação melhorada de hidrocarbonetos. Em 2020, iniciou o seu Mestrado na Universidade Estadual de Campinas (UNICAMP) em Campinas – Brasil, abordando o estudo geológico de fácies na Bacia de Santos, com foco nas facies carbonáticas da Formação Barra Velha, através de perfis de poço, algoritmos de aprendizagem de máquina e propagação 3D destas fácies por meio de geoestatística.

AGRADECIMENTO

Em primeiro lugar, quero agradecer a essa entidade suprema que permitiu que tudo isso acontecesse, a quem muitos chamam Deus. Seguido por aqueles que foram sempre minha razão de estar na frente, meu pai e minha mãe (Luis Arnoldo Páez e Ilma Sarmiento), meus modelos de honestidade, perseverança e coragem. Não poderia deixar a minha irmã (Lina Páez) sendo uma pessoa com quem aprendi muito e me inspira a continuar sempre.

Também gostaria de agradecer a Daniel Rojas Caro, meu namorado, ele entrou na minha vida, acompanhou e me ajudou em tantos aspectos de tal maneira que uma parte fundamental de tornar tudo isso possível é graças a ele. O Spike, o nosso cachorro que nos acompanhou sempre em momentos de solidão com suas loucuras. A Maria Cabrera, uma amiga que esteve conosco, principalmente em momentos difíceis como os vividos durante a pandemia.

Acho que estes dois anos de investigação resultaram em novos conhecimentos e descobertas bastante interessantes graças a uma excelente orientação, por isso quero primeiro agradecer ao meu orientador o professor Alessandro Batezelli, sempre pontual, crítico, dinâmico e primeiro um excelente ser humano que sempre me proporcionou com o seu apoio e compreensão ao longo deste tempo. Eu também fui ajudado com opiniões, discussões e conhecimentos do André Pontara, que sempre me aconselhou sobre algoritmos de aprendizado automático e teve muita paciência comigo; À Leidy Delgado que esteve sempre disponível para responder às minhas dúvidas sobre os aspectos da petrofísica dos hidrocarbonetos e sempre me forneceu material de apoio, pessoas muito simpáticas e graças a eles por trabalharem em conjunto muitos resultados desta investigação puderam ser realizados. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Programa de Excelência Acadêmica (PROEX) código de financiamento 88887.487124/2020-00. Também o presente trabalho foi realizado com apoio da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), processo SEI nº 48610.208265/2020-54 de 05/06/2020.

Quero agradecer a todos os professores que tive durante o mestrado, aprendi muito com eles e sei que poderei ter o melhor de cada uma de suas disciplinas para a minha vida profissional. Principalmente à professora Patrícia Aquino que me ensinou português desde zero e me ajudou a entender muito essa língua maravilhosa e à Ana Fontana, uma amiga que trabalhava na DAC especificamente no atendimento a estrangeiros quando entrei no programa, e ela nos ajudou muito a ter todos os nossos documentos em ordem aqui no Brasil.

Conheci poucas pessoas aqui no Brasil, mas muito valiosas, sei que embora não tenha sido possível compartilhar muito tempo, elas sempre estiveram lá me acompanhando e me fazendo sentir parte do IG. Não poderia deixar de lembrar de todos os meus amigos que estiveram na Colômbia durante o desenvolvimento deste mestrado no Brasil, principalmente Mayra Sierra, Erika Ojeda e Leidy Correa, três pessoas que sempre admirei e seu apoio é incondicional, me acompanhando à distância com conversas interessantes, Mensagens de carinho e memes.

RESUMO

Os reservatórios carbonáticos correspondem a cerca de 60% das reservas mundiais de hidrocarbonetos, representando um ativo importante para a indústria de petróleo e gás para os países nos quais a economia depende desses recursos naturais. Os carbonatos sofrem processos pós-deposicionais que resultam em alterações de suas propriedades tornando-os heterogêneos. Alterações como dissolução, recristalização ou precipitação alteram a produtividade e o fluxo. Desta maneira, a modelagem tridimensional de reservatórios carbonáticos desde a exploração até os processos de recuperação de óleo aprimorada é um desafio tanto para a Geociências quanto para a Engenharia de Reservatórios. A presente pesquisa pretende caracterizar litologicamente três reservatórios carbonáticos do Pré-sal brasileiro, suas propriedades petrofísicas e sua relação com unidades de fluxo. Modelos litológicos e auxiliam na determinação da viabilidade econômica de próximos projetos de exploração de hidrocarbonetos nos campos de Berbigão, Sururu, Atapu e outros locais do Pré-sal brasileiro. A geração de um modelo de eletrofácies multi-1D utilizando vários poços permite entender a estratigráfica do reservatório, considerando os perfis elétricos interpretados e as fotos de lâminas delgadas obtidas na área de interesse. Atualmente, a implementação de algoritmos de aprendizado de máquina tem gerado resultados muito mais precisos na predição dos tipos de rochas que podem ser encontradas em reservatórios carbonáticos, que tende a ser um processo difícil devido a mudanças diagenéticas e alterações geológicas presentes nas diferentes camadas de rochas. Propriedades petrofísicas como porosidade, permeabilidade e saturações de água e óleo caracterizam e determinam as áreas mais propícias ao fluxo de fluídos. Portanto, a relação entre as diferentes eletrofácies, as propriedades petrofísicas presentes nas petrofácies modeladas através de algoritmos de aprendizagem de máquina para e suas relações com as diferentes unidades de fluxo, adicionalmente seu comportamento em um modelo tridimensional, fornecem uma ferramenta adicional mais precisa na caracterização de pesquisas petrolíferas atuais e futuras nos campos do Pré-sal brasileiro e reservatórios carbonáticos em geral.

Palavras-chave: Pré-sal brasileiro; carbonatos; eletrofácies; petrofísica; aprendizagem de máquina.

ABSTRACT

Carbonate reservoirs correspond to approximately 60% of the world's hydrocarbon reserves and represent an important asset for the world's oil and gas industry especially in countries whose their economic incomes depend on these natural resources. Carbonates undergo post-depositional processes that result in changes in their properties that make them heterogeneous. Changes such as dissolution, recrystallization or precipitation modify the productivity and flow in these reservoirs. Therefore, the three-dimensional modeling of carbonate reservoirs involved at various levels of the industrial chain processes from exploration to enhanced recovery processes. This research aims to characterize three carbonate reservoirs of the Brazilian pre-salt, their petrophysical properties and their relationship with flow units. Lithological and petrophysical models can be generated to aid characterizing the economic viability of upcoming hydrocarbon exploration projects in the Berbigão, Sururu, Atapu fields and other Brazilian pre-salt locations. The generation of a multi-1D electrofacies model using several wells allows understanding stratigraphy of the reservoir, considering the interpreted electrical profiles and the thin sections taken in area of interest. Currently, the implementation of machine learning algorithms has given exactly accurate results in predicting the types of rocks that can be found in carbonate reservoirs. Petrophysical properties such as porosity, permeability and water and oil saturations characterize and determine the areas with the best flow units. Therefore, the relationship between the different lithologies existing in the electrofacies and the petrophysical properties present in the petrofacies modeled through machine learning algorithms, their relationships with the different flow units and their behavior in a three-dimensional model representing spatially reservoir volume, providing an additional tool in characterizing current and future oil research in Brazilian pre-salt fields and general carbonate reservoirs.

Keywords: Brazilian pre-salt; carbonates; electrofacies; petrophysics; machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1. Localização da Bacia de Santos com a indicação de seus limites (Viana <i>et al.</i> , 2018).	25
Figura 2. Localização da área de estudo, o polígono do Pré-sal e os campos de Berbigão, Sururu e Atapu respectivamente (modificado de GeoANP).	26
Figura 3. Carta estratigráfica da bacia de Santos (modificado de Moreira <i>et al.</i> , 2007).....	27
Figura 4. Gráfico de permeabilidade relativa. Kro é a permeabilidade relativa ao óleo e Krw é a permeabilidade relativa à água (modificado de Lucia <i>et al.</i> , 2003).....	34
Figura 5. Gráfico de porosidade Vs permeabilidade para rochas carbonáticas (modificado de Lucia <i>et al.</i> , 2003).....	35
Figura 6. Curvas de pressão capilar típicas mostrando curvas de drenagem e embebição (modificado de Lucia <i>et al.</i> , 2003).	37
Figura 7. Diagrama mostrando poros menores sendo preenchidos com um fluido não umectante (óleo), deslocando um fluido umectante (água) conforme a pressão capilar aumenta linearmente com a altura do reservatório. Onde (A) Apenas o maior poro contém óleo na base do reservatório. (B) Poros menores são preenchidos com óleo conforme a pressão capilar e a altura do reservatório aumentam. (C) Os poros menores são preenchidos com óleo em direção ao topo do reservatório (modificado de Lucia <i>et al.</i> , 2003).	38
Figura 8. Comportamento da pressão capilar e saturação de água para diferentes zonas reservatórias (Crain, 2002).	39
Figura 9. Integração de dados geológicos espaciais com dados de engenharia numérica por meio de estudos da estrutura rochosa (modificado de Lucia <i>et al.</i> , 2003).	39
Figura 10. Exemplos de estruturas de rocha calcária não-vugulares. (a) <i>Grainstone</i> , (b) <i>Grainstone</i> com algum espaço poroso vug, (c) e (d) <i>Packstone</i> , (e) <i>Packstone</i> dominado por lama, (f) <i>Packstone</i> dominado com espaço poroso vug, (g) <i>Wackestone</i> com microporosidade e (h) Microporosidade em <i>Wackestone</i> – Imagem de SEM (Modificado de Lucia <i>et al.</i> ; 2003).	41
Figura 11. Estruturas de dolomitas não-vugulares. (a) Dolo- <i>Grainstone</i> com oóide cristalino tamanho médio. (b) Dolo- <i>Grainstone</i> cristalino tamanho grande. (c) Dolo- <i>Packstone</i> peloide fino cristalino tamanho médio dominado por grãos com anidrita poiquilotópica. (d) <i>DoloPackstone</i> granulado cristalino médio peloide com anidrita poiquilotópica (branco). (e)	

DoloWackestone cristalino fino. (f) DoloWackestone meio cristalino. (g) DoloWackestone cristalino grande. (h) Grande cristalino dolostone (Modificado de Lucia <i>et al.</i> ; 2003).	42
Figura 12. Diagrama ternário mostrando a classificação de litofácies para sedimentos gerados <i>in-situ</i> (Gomes <i>et al.</i> , 2020).	46
Figura 13. Novo esquema de classificação, compreendendo três diagramas triangulares, proposto para descrever todas as litofácies da Formação Barra Velha (Gomes <i>et al.</i> , 2020).	47
Figura 14. Duas classes de observações, mostradas em azul e em roxo (James <i>et al.</i> , 2013).	50
Figura 15. Exemplo de um Kernel Support Vector Machine Polinomial (SVM Polinomial) com um Kernel polinomial de grau 3 aplicado a dados não lineares (James <i>et al.</i> , 2013).	52
Figura 16. Exemplo de um Kernel Support Vector Machine Radial (SVM Radial) mostrando um agrupamento radial (James <i>et al.</i> , 2013).	52
Figura 17. Fluxograma de trabalho implementado.	57
Figura 18. Fluxograma de trabalho de algoritmos de aprendizagem de máquina SVM e K-Means Clustering.	60
Figura 19. Perfis geofísicos no poço 1 (1-BRSA-618-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	65
Figura 20. Perfis geofísicos no poço 2. (3-BRSA-891A-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	66
Figura 21. Perfis geofísicos no poço 3. (3-BRSA-1032-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	67
Figura 22. Perfis geofísicos no poço 4 (3-BRSA-1132-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	68

Figura 23. Perfis geofísicos no poço 5 (3-BRSA-1172-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	69
Figura 24. Visão geral de perfis geofísicos no poço 6 (4-BRSA-1126-RJS). Raios gama (GR), Densidade (RHOB), nêutron (NPHI), sônico (DTC), resistividade (RT), média logarítmica do tempo 2 (T2LM), Ressonância Magnética Nuclear (RNM), volumem dos grãos tamanhos tipo argila (Vclay).....	70
Figura 25. Perfis geofísicos no poço 7 (9-BRSA-1212-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); e Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF).....	71
Figura 26. Perfis geofísicos no poço 8 (9-BRSA-1284-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).	72
Figura 27. Modelos de porosidade total (PHIT) e modelos de porosidade efetiva (PHIE) calibrados com dados de laboratório no poço 2 (3-BRSA-891A-RJS). Os pontos amarelos e triângulos vermelhos representam os dados de laboratório de petrofísica efetiva e permeabilidade horizontal no testemunho.....	73
Figura 28. Modelos petrofísicos no poço 3 (3-BRSA-1032-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.	74
Figura 29. Modelos petrofísicos no poço 4 (3-BRSA-1132-RJS). Modelo de argilas, modelo de porosidade efetiva além de dados petrofísicos de porosidade efetiva (pontos amarelos), modelo de permeabilidade horizontal (KTIM) e dados petrofísicos de permeabilidade horizontal (triângulos vermelhos), modelo de saturação de água e óleo a partir do OWC.	75
Figura 30. Modelos petrofísicos no poço 5 (3-BRSA-1172-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.	76

Figura 31. Modelos petrofísicos no poço 6 (4-BRSA-1226-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.	77
Figura 32. Lâmina delgada de <i>Grainstone</i> com alta presença de dolomita.....	79
Figura 33. Lâmina delgada de <i>Spherulitstone</i> com pequenas amostras de Dolomita (círculos vermelhos).	80
Figura 34. Lâmina delgada de <i>Schrubstone</i> com pequenas amostras de Dolomita. Onde pode-se observar espaços porosos (círculo azul) e esses espaços podem ser preenchidos por calcita que se transforma em dolomita devido a alterações diagenéticas (círculos vermelho).....	80
Figura 35. Lâmina delgada de Laminite com a presença de materiais ferrosos (círculos vermelhos) e presença de porosidade secundária (círculo azul).....	81
Figura 36. Matriz de confusão do algoritmo de aprendizado de máquina supervisionado (SVM Radial).	82
Figura 37. Gráfico de validação de precisão da metodologia SVM Radial.	83
Figura 38. Classificação das cores de eletrofácies.	83
Figura 39. Classificação das cores de petrofácies.	83
Figura 40. Modelo de eletrofácies litológicas desde o SVM Radial para os poços 1, 2, 3 e 4.	84
Figura 41. Modelo de eletrofácies litológicas desde o SVM Radial para os poços 5, 6, 7 e 8.	85
Figura 42. Cluster plot das petrofácies em RStudio. As cores neste gráfico foram automáticas e representam o verde é a petrofácies não reservatório, marrom é a petrofácies possível reservatório e azul é a petrofácies Reservatório.	86
Figura 43. Modelo de petrofácies previstas por K-Means Clustering para os poços 1, 2, 3 e 4.	87
Figura 44. Modelo de petrofácies previstas por K-Means Clustering para os poços 5, 6, 7 e 8.	88
Figura 45. Gráfico estratificado modificado de Lorenz.	89
Figura 46. Gráfico de discretização das unidades de fluxo horizontal.....	89
Figura 47. Cores para cada unidade de fluxo.	90
Figura 48. Comparação do DTC Vs GR para o poço 2.....	91
Figura 49. Comparação do NPHI Vs GR para o poço 2.	92
Figura 50. Comparação do RHOB Vs GR para o poço 2.....	93
Figura 51. Comparação do T2LM Vs GR para o poço 2.	94
Figura 52. Comparações entre eletrofácies previstas e lâminas delgadas para os poços 2, 3 e 7.	95

Figura 53. Comparação petrofácies Vs dados laboratoriais de PHIE e KTIM para o poço 4.	95
Figura 54. Comparação de eletrofácies Vs unidades de fluxo para o poço 4.	96
Figura 55. Histograma de relacionamento entre eletrofácies e unidades de fluxo.	96
Figura 56. Comparação de eletrofácies Vs unidades de fluxo para o poço 8.	97
Figura 57. Histograma de relacionamento entre petrofácies e unidades de fluxo.	97
Figura 58. Poços localizados com seus respectivos desvios espacialmente localizados.	98
Figura 59. Calibração do perfil sônico com os Checkshots.	99
Figura 60. Criação da traça sintética por método estatístico e 0° de fase.	99
Figura 61. Coeficientes de reflexão para a Formação Barra Velha.	100
Figura 62. Exemplo de amarre sísmica-poço manual para o poço 1.	101
Figura 63. Aplicação de filtro DSMF em um <i>in-line</i> .	102
Figura 64. Aplicação do FEF em um <i>cross-line</i> .	103
Figura 65. Aplicação do atributo sísmico TFL em um <i>in-line</i> .	103
Figura 66. Interpretação de falhas nos campos Berbigão, Sururu e Atapu.	104
Figura 67. Interpretação do horizonte da Formação Barra Velha.	105
Figura 68. Interpretação do horizonte da Formação Itapema.	105
Figura 69. Esqueleto da malha estrutural 3D ou Grid 3D.	106
Figura 70. Vista aérea geral da propagação de eletrofácies SVM por meio de geoestatística.	107
Figura 71. Vista lateral geral da propagação de eletrofácies SVM por meio de geoestatística.	108
Figura 72. Seção estratigráfica entre 2 poços da propagação de eletrofácies por meio de geoestatística.	108
Figura 73. Vista aérea geral da propagação de petrofácies UM por meio de geoestatística.	109
Figura 74. Vista lateral geral da propagação de petrofácies UM por meio de geoestatística.	109
Figura 75. Seção estratigráfica entre 2 poços da propagação de petrofácies por meio de geoestatística.	110
Figura 76. Lâmina delgada 1 de <i>Grainstone</i> apresentando poros tipo vug (círculos vermelhos).	112
Figura 77. Lâmina delgada 2 de <i>Grainstone</i> apresentando poros tipo vug (círculos vermelhos).	113
Figura 78. Associações de fácies para a área de estudo definidas com base na interpretação. Na segunda coluna estão as fácies de cada associação e suas respectivas siglas (Rebelo <i>et al.</i> , 2022).	115

Figura 79. Histogramas mostrando a distribuição de fácies em cada unidade de fluxo (Rebelo *et al.*, 2022)..... 116

LISTA DE TABELAS

Tabela 1. Classificação para cada uma das litofácies disponíveis no poço 3-BRSA-891A-RJS.	78
Tabela 2. Classificação as litofácies disponíveis no poço 9-BRSA-1212-RJS.....	79
Tabela 3. Classificação para cada uma das litofácies disponíveis no poço 9-BRSA-1284-RJS.	79
Tabela 4. Cut-offs de Log (FZI), FZI, RQI, ϕ_e e K discretizados para cada unidade de fluxo.	90
Tabela 5. Listagem de distâncias entre poços na área de estudo.....	107
Tabela 6. Média ponderada das principais propriedades da Formação Barra Velha dos campos Berbigão, Sururu e Atapu comparados com o campo Búzios.	111
Tabela 7. Valores típicos da Equação de Archie.....	127

LISTA DE ABREVIATURAS E SIGLAS

LQC: *Line quality control* (Control de qualidade Linear).

SVM: *Support Vector Machine* (Vector de máquina suportado).

UM: *Unsupervised method* (Método não supervisionado).

OWC: *Oil-Water contact* (Contato água-óleo).

Grainstone: Rocha tipo grãos.

Laminite: Rocha tipo Laminito.

Muddy Spherulitestone: Rocha tipo lama com esferulitos.

Mudstone: Rocha tipo lama.

Packstone: Rocha tipo grãos compactado.

Shrubby Spherulitestone with Mud: Rocha tipo arbusto esferulito com lama.

Shrubstone: Rocha tipo arbusto.

Spherulitestone: Rocha tipo esferulito.

Spherulitic Mudstone: Rocha tipo esferulito com lama.

Spherulitic Shrubstone: Rocha tipo esferulito arbustiforme.

Poço 1: 1-BRSA-618-RJS.

Poço 2: 3-BRSA-891A-RJS.

Poço 3: 3-BRSA-1032-RJS.

Poço 4: 3-BRSA-1132-RJS.

Poço 5: 3-BRSA-1172-RJS.

Poço 6: 4-BRSA-1226-RJS.

Poço 7: 9-BRSA-1212-RJS.

Poço 8: 9-BRSA-1284-RJS.

LISTA DE SÍMBOLOS

Q: Taxa de fluxo.

K: Permeabilidade [mD].

μ : Viscosidade do fluido.

$\Delta P/L$: Queda potencial através da amostra horizontal.

A: Área da seção transversal da amostra.

Φ : Porosidade.

Kz: Constante de Kozeny.

S_p^2 : Área da superfície quadrada.

P_w : Pressão da fase da água.

P_o : Pressão da fase de óleo.

H: Altura acima do nível de pressão capilar zero.

ρ_o : Densidade da fase de óleo.

ρ_w : Densidade da fase aquosa.

Vsh: Modelo de argilas.

GRlog: Resposta do perfil Gamma Ray [API].

GRsand: Resposta do perfil Gamma Ray para argilas limpas [API].

GRshale: Resposta do perfil Gamma Ray para argilas [API].

X_i : Projeção de um ponto de dados pertencente ao *Cluster* C_k .

μ_k : É o valor médio dos pontos atribuídos ao *Cluster* C_k .

φ : Porosidade [%].

C, m, n: São os parâmetros envolvidos nos modelos.

S_{wi} : Saturação de água irreduzível (fração).

SUMÁRIO

1. Introdução	22
2. Objetivos.....	24
2.1. Objetivo geral	24
2.2. Objetivos específicos.....	24
3. Geologia da área de estudo	25
3.2. Contexto geológico	26
3.2.2. Fase Pós- <i>Rifte</i>	28
3.2.3. Fase <i>Drifte</i>	30
4. Fundamentação teórica.....	32
4.1. Propriedades petrofísicas	32
4.1.1. Porosidade	32
4.1.2. Permeabilidade	33
4.1.3. Permeabilidade relativa	33
4.1.4. Tamanho de poros e saturação de fluidos.....	34
4.1.5. Saturação	35
4.2. Estrutura do tipo de rocha	38
4.3. Relação entre tipo de rocha e permeabilidade	40
4.3.1. Calcários	40
4.3.2. Dolomita	40
4.4.1. Raios Gama (GR)	43
4.4.2. Volume de argila (Vsh)	43
4.4.3. Perfis acústicos (DTC)	44
4.4.4. Perfis de resistivades (RT).....	44
4.4.5. Perfis de Densidade (RHOB)	44
4.4.6. Perfis Neutrão (NPHI).....	45

4.5.	Fácies	45
4.5.1.	Classificação de litofácies	46
4.6.	Algoritmos de aprendizagem de máquina.....	48
4.6.1.	Algoritmos de aprendizagem de máquina supervisionados	48
4.6.1.1.	<i>Support Vector Machine (SVM)</i>	48
4.6.2.	Algoritmos de aprendizagem de máquina não supervisionados	53
4.6.2.1.	<i>K-Means Clustering</i>	53
4.7.	Geoestatística	54
4.8.	Atributos e filtros sísmicos	55
4.8.1.	Dip Steering.....	55
4.8.2.	<i>Dip Steered Median Filter (DSMF)</i>	55
4.8.3.	<i>Fault Enhancement Filter (FEF)</i>	56
4.8.4.	<i>Thinned Fault Likelihood (TLF)</i>	56
5.	Materiais e métodos	57
5.1.	Estágio 1: modelagem multi-1D de eletrofácies, petrofácies e unidades de fluxo	57
5.1.1.	Inventário de dados.....	57
5.1.2.	Modelagem petrofísica	58
5.1.3.	Geração de eletrofácies e petrofácies através de algoritmos de aprendizagem de máquina	59
5.1.4.	Geração de unidade de fluxo	60
5.2.	Estágio 2: filtros, atributos e interpretação sísmica	62
5.2.1.	Amarração sísmica-poço	62
5.2.2.	Filtros e atributos sísmicos	62
5.2.3.	Interpretação sísmica	63
5.3.	Estágio 3: modelagem estrutural 3D.....	63
5.3.1.	Modelo estrutural 3D.....	63
5.3.2.	Geoestatística.....	63

6.	Resultados	64
6.1.	Estágio 1: modelagem multi-1D de eletrofácies, petrofácies e unidades de fluxo	64
6.1.1.	Inventário de dados.....	64
6.1.2.	Modelagem petrofísica	73
6.1.3.	Geração de eletrofácies e petrofácies através de algoritmos de aprendizagem de máquina	78
6.1.4.	Geração de unidades de fluxo.....	89
6.1.5.	Comparações	90
6.2.	Estágio 2: filtros, atributos e interpretação sísmica.	98
6.2.1.	Amarração sísmica-poço.	98
6.2.2.	Aplicação de filtros e atributos sísmicos	102
6.2.3.	Interpretação sísmica	104
6.3.	Estágio 3: modelagem estrutural 3D.....	104
6.3.1.	Modelo estrutural 3D.....	104
6.3.2.	Geoestatística.....	106
7.	Discussões	111
7.1.	Modelos petrofísicos e interpretação de lâminas delgadas.....	111
7.2.	Implementação de algoritmos de aprendizagem de máquina supervisionados e não supervisionados (<i>SVM Radial</i> e <i>K-Means Clustering</i>)	113
7.3.	Identificação de unidades de fluxo	114
8.	Conclusões	117
9.	Referências.....	119
10.	Anexos.....	127

1. Introdução

As indústrias de petróleo no mundo dependem de melhores processos otimizados para a caracterização de reservatórios para reduzir os riscos associados ao desenvolvimento de novos campos. Entender melhor as estruturas geológicas dos campos de produção e identificar novas reservas de hidrocarbonetos dependem principalmente de ferramentas como perfis de poços e os testes de laboratório em testemunhos de sondagem (Arns *et al.*, 2004).

Um dos desafios na indústria do petróleo é compreender e caracterizar os reservatórios carbonáticos, sobretudo em relação ao uso da sísmica que fica comprometida devido à espessa camada de sal que sela esses reservatórios prejudicando o sinal sísmico. De acordo com Due & MacGregor (2010), métodos baseados em perfis de poços são usados para monitorar o reservatório com sucesso, visto que as medições podem ser feitas próximas ao reservatório. Os métodos acústicos ou de condutividade elétrica são utilizados pois possuem relação direta com saturação de fluido na rocha, e podendo ser interpretados por métodos estatísticos.

Os reservatórios carbonáticos do Pré-sal brasileiro encontram-se em profundidades superiores a 5.000 m, considerando uma coluna d'água > 2000 m. Os carbonatos do Pré-sal são formados predominantemente por calcita com quantidades variáveis de dolomita e quartzo. Minerais pesados e argilas ricas em magnésio, rochas vulcânicas intrusivas e extrusivas também podem ser encontrados ocasionalmente. Portanto, a avaliação de litologias é desafiadora nas formações do Pré-sal da Bacia de Santos devido as altas incertezas próprias da anisotropia vertical e horizontal nas diferentes camadas de rocha (Du *et al.*, 2020).

Desta maneira, a identificação de litofácies é uma etapa básica muito importante para outros estudos geológicos, como a construção de modelos de sedimentação e análise de ciclos sedimentares. Para poços específicos, as informações sobre litofácies são obtidas através de testemunhos, lâminas delgadas e perfis geofísicos (Baldwin *et al.*, 1990; Carrasquilla *et al.*, 2008). Porém, devido aos altos custos de uma sonda de perfuração no Pré-sal, não é possível obter amostras de testemunho de todos os poços. A maior parte dos materiais rochosos coletados no Pré-sal correspondem às amostras de calha, que são materiais triturados e que na maioria das vezes constituem um registro incompleto do reservatório além de materiais triturados com alto grau de incerteza em relação ao seu posicionamento no poço. (Morais, 2013).

A interpretação do registro carbonático nos reservatórios do Pré-sal não é muito precisa devido à complexidade das litofácies. Dessa forma, métodos estatísticos e métodos de aprendizado de máquina estão sendo testados (Tang & White, 2008; Insua *et al.*, 2015) como por exemplo o *Support Vector Machine (SVM)*, um método de aprendizagem de máquina supervisionado que apresenta resultados muito próximos aos dados de laboratório. Métodos de aprendizado de máquina não supervisionados (*Unsupervised Methods, UM*), como *K-Means Clustering*, permitem gerar agrupamentos mais precisos de propriedades em comum.

As diferentes técnicas de inteligência artificial possuem três características principais: determinar probabilidades diferentes (em problemas onde as metodologias não são claramente definidas), uso da aprendizagem (explorar a estrutura do problema e a redução do número de possibilidades para classificar ou agrupar) e predição (generalizar na metodologia para determinar os dados intrinsecamente similares) (Russell & Norving, 2004). Segundo Monard e Baranauskas (2005), é importante compreender a capacidade e os limites dos distintos algoritmos de aprendizado de máquina utilizando alguma metodologia que permita avaliar os conceitos induzidos pelos algoritmos para cada tipo de problema para resolver.

Este estudo tem o objetivo de identificar as unidades de fluxo na Formação Barra Velha do Pré-sal brasileiro para estabelecer relações com as eletrofácies e petrofácies feitas através de algoritmos de aprendizagem de máquina. Para isto foram utilizados dados de oito (8) poços e linhas sísmicas que compreendem a Formação Barra Velha nos campos de Berbigão, Sururu e Atapu no Pré-sal da Bacia de Santos, a fim de realizar a modelagem petrofísica multi-1D, uso de atributos sísmicos e a modelagem estrutural 3D da área de estudo.

Desta maneira, foram identificadas 4 eletrofácies e 3 petrofácies através da interpretação dos perfis de poço e do uso de algoritmos supervisionados e não supervisionados, sua relação com as unidades de fluxo em escala multi-1D e 3D por meio de análises geoestatísticas, gerando um processo de transferência de escalas (*up-scaling*) desde um nível de poço com as eletrofácies e petrofácies preditas a um tamanho de malha sísmica aplicando propagação estatística pela método de truncamento Gaussiano preenchendo o todo o volume tridimensional interpretado. A nova abordagem deste estudo é o uso dos algoritmos de aprendizagem de máquina na classificação de eletrofácies e petrofácies fornece os dados para a identificação das zonas de fluxo da Formação Barra Velha e contribui para reduzir lacuna do conhecimento da geologia do petróleo do Pré-sal da Bacia de Santos.

2. Objetivos

2.1. Objetivo geral

Identificar a relação existente entre as unidades de fluxo e os modelos de petrofácies e eletrofácies obtidas desde a aplicação de feitas através de algoritmos de aprendizagem de máquina. Na Formação Barra Velha do Pré-sal brasileiro nos Campos de Berbigão, Sururu e Atapu.

2.2. Objetivos específicos

- Determinar modelos petrofísicos de porosidade, permeabilidade e saturações de água e óleo na Formação Barra Velha.
- Obter modelos de eletrofácies e petrofácies multi-1D na Formação Barra Velha, a partir da descrição de lâminas delgadas, interpretação de perfis geofísicos e geração de modelos petrofísicos a partir de algoritmos de aprendizado de máquina.
- Analisar relações entre os diferentes perfis geofísicos para cada uma das eletrofácies e petrofácies classificadas, e relações com as unidades de fluxo presentes na Formação Barra Velha.
- Interpretar falhas e horizontes sísmicos para gerar um modelo estrutural tridimensional da área de estudo.
- Preencher a malha estrutural 3D com as diferentes eletrofácies e petrofácies através de análises geoestatística.

3. Geologia da área de estudo

Neste capítulo serão apresentadas a localização geográfica e o contexto geológico no qual estão delimitados os campos de Berbigão, Sururu e Atapu no espaço.

3.1. Localização

A Bacia de Santos está localizada no Sudeste do Brasil (paralelos 23° e 28° Sul), e sua extensão abrange os litorais dos estados do Rio de Janeiro, São Paulo, Paraná e Santa Catarina. Sua área é de cerca de 350.000 km² e sua cota batimétrica máxima é 3.000 m (Vidal *et al.*, 2003). Geologicamente, segundo Moreira *et al.* (2007), está delimitada ao norte com a Bacia de Campos pelo Alto de Cabo Frio e ao sul com a Bacia de Pelotas pelo Alto de Florianópolis (Figura 1). O limite oeste da bacia é representado pelos cinturões das serras costeiras como o Maciço da Carioca, Serras do Mar e da Mantiqueira e a leste (limite oriental) da bacia se estende até o sopé do Platô de São Paulo (Gamboa *et al.*, 2008).

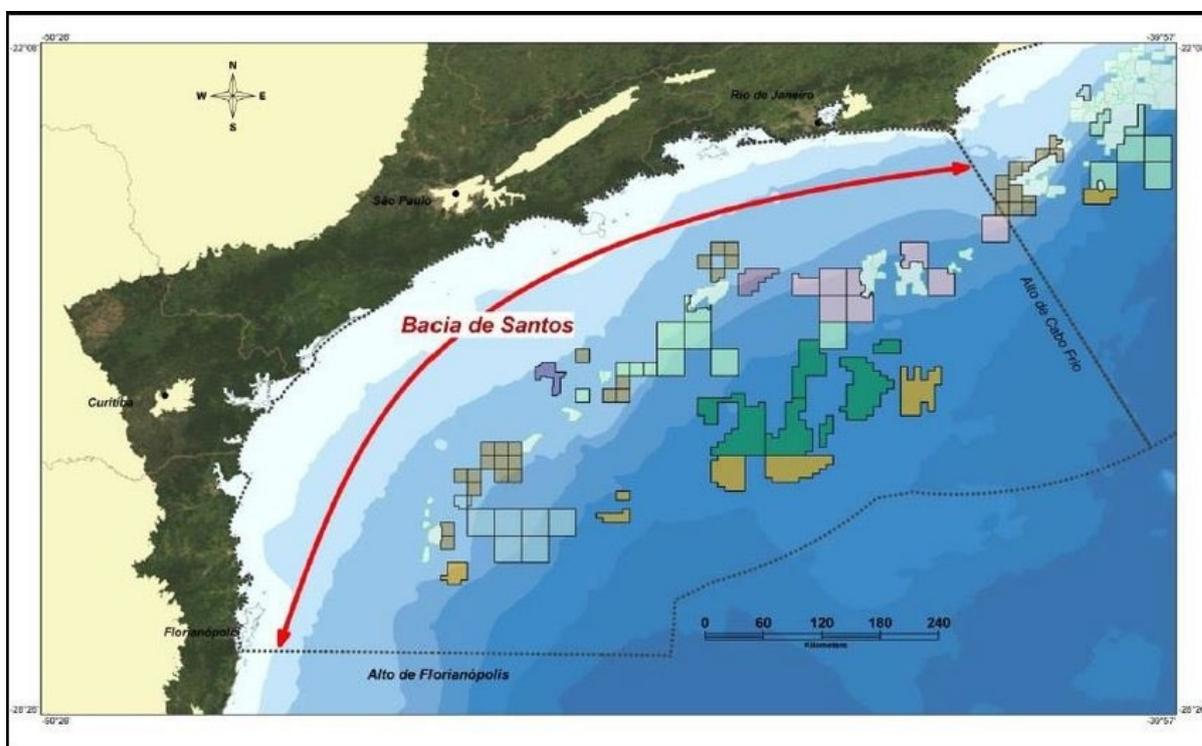


Figura 1. Localização da Bacia de Santos com a indicação de seus limites (Viana *et al.*, 2018).

Os reservatórios carbonáticos do Pré-sal da Bacia de Santos estão localizados a uma distância de cerca de 300 km da costa em profundidades entre 5.000 e 6.500 m, incluindo uma coluna de água entre 2.000 e 3.000 m e uma camada de sal autóctone de 2.000 m na região dos campos de Berbigão, Sururu e Atapu podem ser observados na Figura 2.

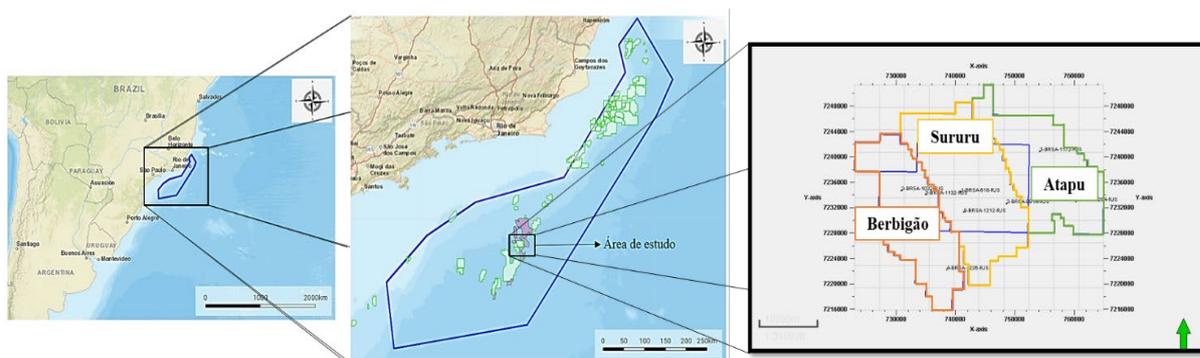


Figura 2. Localização da área de estudo, o polígono do Pré-sal e os campos de Berbigão, Sururu e Atapu respectivamente (modificado de GeoANP).

3.2. Contexto geológico

A origem da Bacia de Santos está relacionada ao evento de *rifteamento* que se iniciou no Eocretáceo e culminou na abertura do Atlântico Sul, responsável pela configuração das principais feições estruturais presentes na bacia, entre elas, o Platô de São Paulo e o Alto de Florianópolis. Seus espessos evaporitos representam o extremo sul da bacia evaporítica aptiana, e em conjunto com os depósitos da fase *drifte* constituem elemento importante para a evolução dessa porção da margem passiva leste do Brasil (Mohriak, 2001).

Do ponto de vista geológico, a Bacia de Santos apresenta duas características importantes em relação às demais bacias que compartilham o Pré-sal (os reservatórios de hidrocarbonetos abaixo da seção evaporítica estão distribuídos entre as bacias de Santos e Sergipe-Alagoas): (i) inexistência de porção emersa da bacia (Garcia, 2012), e (ii) ocorrência de magmatismo formador do embasamento na bacia, representado pela Formação Camboriú, do Neocomiano Superior (Moreira *et al.*, 2007). De acordo com Moreira *et al.* (2007), a história geológica da Bacia de Santos pode ser dividida em três fases: *Rifte*, *Pós-Rifte* e *Drifte* como pode-se observar na Figura 3.

3.2.1. Fase *Rifte*

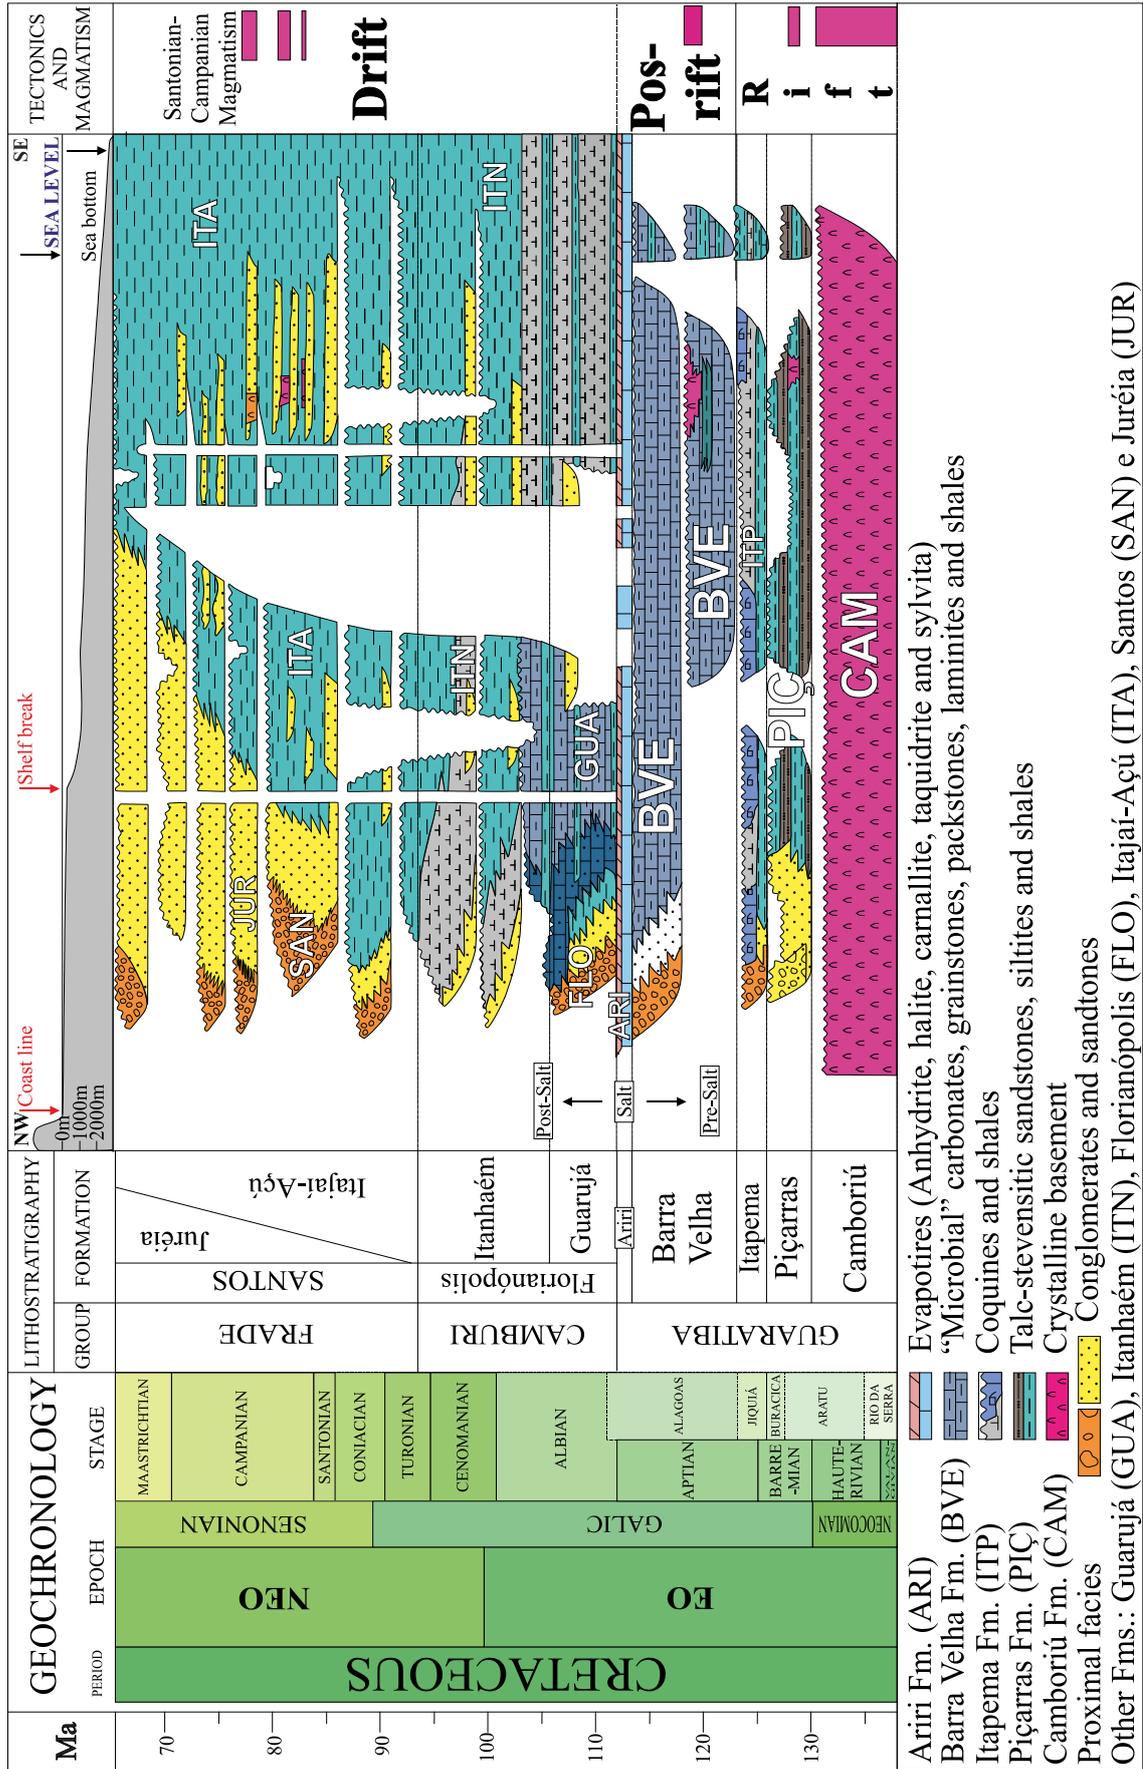


Figura 3. Carta estratigráfica da bacia de Santos (modificado de Moreira *et al.*, 2007)

A separação entre as placas Sul-americana e Africana iniciou-se no Cretáceo Inferior, atuando de forma progressiva, diacrônica e propagando-se de sul para o norte (Mohriak, 2003; Bueno, 2004). Na Fase *Rifte*, a tectônica extensional atuou como mecanismo gerador de espaço para acomodação sedimentar. A subsidência mecânica gerou falhas normais na bacia que constituem blocos falhados e rotacionados que delimitam grábens que alojam os depósitos sedimentares, representados pela sequência Pré-sal (Milani *et al.*, 2007).

Na Fase *Rifte* a estratigrafia do Grupo Guaratiba é representada pelas Formações Camboriú, Piçarras e Itapema. A primeira formada por basaltos toleíticos, originados pelos primeiros derrames de lavas da Formação Serra Geral, ocorridos entre o Jurássico Superior e o Cretáceo Inferior na Bacia do Paraná e estendendo-se até as nas bacias marginais do sudeste do Brasil (Mohriak, 2012). A Formação Piçarras, corresponde à sedimentos de leques aluviais depositados no Andar Barremiano. Nas porções proximais apresenta conglomerados e arenitos polimíticos (quartzo, basalto e feldspato), enquanto nas porções mais distais são encontrados arenitos, siltitos e folhelhos de composição de talco estevensítico (esmectita e hidrato de silicato de magnésio) sendo correspondente com este tipo de ambiente deposicional lacustre mais distais (Moreira *et al.*, 2007).

Uma discordância separa o topo da Formação Piçarras da base da Formação Itapema. Essa formação corresponde os sedimentos depositados do Neobarremiano ao Eoaptiano. Com presença de conglomerados e arenitos como sedimentos de leques aluviais sedimentados nas seções próximas, intercalando calcirruditos (constituídos por fragmentos de conchas de pelecípodes frequentemente dolomitizados e/ou silicificados, e folhelhos escuros), depositadas na bacia durante as primeiras incursões marinhas (Moreira *et al.*, 2007; Arai, 2014).

3.2.2. Fase Pós-Rifte

As incursões marinhas que originaram o Oceano Atlântico Sul, eram provenientes do Oceano Atlântico Central, na região do Caribe (Dias-Brito, 1995). Essa bacia, que mostrava uma assembleia de micro fósseis do domínio tetiano, foi impedida de alcançar a Bacia de Pelotas ao sul, em virtude das barreiras físicas representadas pelo Alto de Florianópolis e a Dorsal de São Paulo (Arai, 2014). A sedimentação dos evaporitos no Aptiano decorreu das incursões marinhas provenientes da porção meridional do Oceano Atlântico, que periodicamente transpunham a barreira vulcânica. A barreira vulcânica, ao sul da Bacia de Santos constituía-se em uma estrutura restritiva à circulação da água entre o Atlântico Sul

Meridional e o Atlântico Central, situação que só foi superada definitivamente no Neoalbianos devido ao aprofundamento da bacia resultante da subsidência termal (Azevedo, 2004; Mohriak 2012).

O clima árido durante o Aptiano contribuiu com a geração das condições ideais para a acumulação da sequência evaporítica no golfo estreito e alongado que estendia desde a Bacia de Santos até a bacia de Sergipe-Alagoas (Mohriak, 2003, 2012). Durante a deposição dos evaporitos no Aptiano, a subsidência termal não é o processo que gera a redução da atividade das falhas normais. O que aconteceu foi um cessamento do rifteamento (e conseqüente redução na atividade das falhas) no final do Aptiano que deu lugar a subsidência térmica como mecanismo predominante de formação das bacias (fase Sag). (Gamboa *et al.*, 2008; Milani *et al.*, 2007). O pacote evaporítico, com cerca de 2 km de espessura depositou-se em cerca de 600 mil anos (Dias, 2008), tendo uma taxa anormalmente alta de subsidência. A movimentação do sal iniciou-se no Aptiano Superior gerando uma série de falhas lítricas que se propagam para as camadas do Pós-Sal, estabelecendo uma estruturação complexa como almofadas de sal, anticlinais, diápiros e muralhas de sal (Mohriak, 2003).

Estratigraficamente, a bacia apresenta as Formações Barra Velha (carbonatos) e Ariri, (diferentes tipos de sal principalmente halita e anidrita e alguns sais solúveis como taquidrita, carnalita e silvinita). A primeira formação é subdividida em duas sequências separadas por uma Discordância, conhecida como Intra-Alagoas, datada em 117 Ma. Ambas depositadas em ambiente transicional, entre continental e marinho raso desde o Eoaptiano ao Neoptiano, com a deposição de calcários microbiais, estromatólitos e laminitos nas porções proximais e folhelhos nas porções distais no Eoaptiano além da presença de basaltos datados pelo método Ar/Ar em 117 (Ma) (Moreira *et al.*, 2007).

Sobrepostos a Formação Barra Velha, encontram-se os evaporitos da Formação Ariri depositados no Neoptiano em um ambiente de golfo estreito e alongado (Riccomini *et al.*, 2012), constituídos principalmente por halita e anidrita, além da presença de taquidrita, carnalita e, localmente, silvinita. Seu limite superior é dado pela passagem no Pós-Sal entre os evaporitos e os sedimentos siliciclásticos/ carbonáticos das formações Florianópolis e Guarujá (Moreira *et al.*, 2007).

3.2.3. Fase *Drifte*

Nesta fase a subsidência termal possibilitou o aprofundamento da bacia e conseqüentemente a transposição dos obstáculos vulcânicos no limite sul da depressão, entre o Aptiano e Albiano e a abertura do Oceano Atlântico e desenvolvimento de plataforma carbonática e posteriormente siliciclástico (Gamboa *et al.*, 2008; Mohriak, 2012; Garcia, 2012; Arai, 2014).

Esta etapa evolutiva também pode ser caracterizada pela transição de crosta continental para crosta oceânica, com a individualização das placas sul-americana e africana, determinando o término da bacia evaporítica (Mohriak, 2003; Riccomini *et al.*, 2012). Inicialmente o ambiente marinho na bacia é representado pelos sedimentos de águas rasas seguido de expansão do fundo oceânico, aumento da batimetria seguido da deposição sedimentar de águas profundas, que encontra na sedimentação turbidítica a gênese de vários reservatórios de hidrocarbonetos do Pós-Sal da Bacia de Santos (Souza, 2008; Mohriak, 2012).

No Cretáceo Superior houve uma reativação de antigas falhas do embasamento causada o soerguimento das Serra do Mar e da Mantiqueira (Souza, 2008). Do ponto de vista estratigráfico, a bacia nesta fase constitui-se dos Grupos: Camburi, Frade e Itamambuca (Moreira *et al.*, 2007), que por sua vez representam três etapas do desenvolvimento tectonosedimentar da Fase *Drifte*, impactada pela variação eustática, pelo aporte sedimentar e pela tectônica do sal (Garcia, 2012).

Para Moreira *et al.* (2007), o Grupo Camburi representa todos os sedimentos depositados desde os leques aluviais até os pelitos e arenitos batiais que foram depositados após a Formação Ariri até o topo do Cenomaniano. Esta unidade engloba as formações Florianópolis, Guarujá, Itanhaém e o Membro Tombo, incluso na Formação Itanhaém.

O Grupo Frade representa sedimentos depositados dos leques aluviais até os pelitos e arenitos batiais que foram depositados do topo do Cenomaniano até o limite Cretáceo/Paleógeno (Moreira *et al.*, 2007). As seqüências deposicionais desse grupo engloba uma fase de regressão marinha onde o limite da plataforma avançou até 200 km costa adentro (Moreira *et al.*, 2007), gerada pelo soerguimento da Serra do Mar que aportou um grande volume de sedimentos siliciclásticos em direção a bacia, provocando o deslocamento do sal Aptiano para as porções mais distais (Chang *et al.*, 2008).

O Grupo Itamambuca representa todos os sedimentos depositados após o limite Cretáceo/Paleógeno até os dias atuais. Esse grupo inclui depósitos de leques aluviais proximais

até pelitos e arenitos batiais, com ocorrências de sedimentação mista carbonática próximo à quebra da plataforma (Garcia, 2012). O Grupo Itamambuca compreende as formações Ponta Aguda, Iguape, Marambaia e no topo a Formação Sepetiba (Moreira *et al.*, 2007).

4. Fundamentação teórica

Este capítulo procura-se abordar os fundamentos teóricos que embasaram a presente pesquisa. Será dada ênfase para classificação de eletrofácies, petrofácies, propriedades petrofísicas e construção do modelo estrutural 3D.

4.1. Propriedades petrofísicas

Um dos objetivos da caracterização de reservatórios é construir imagens tridimensionais de propriedades petrofísicas, de modo a revisar as definições básicas e medidas laboratoriais de porosidade, permeabilidade, permeabilidade relativa, capilaridade e saturações, apresentando a distribuição do tamanho dos poros como elo entre todas elas (Lucia *et al.*, 2003).

4.1.1. Porosidade

A porosidade é definida como o volume de porosidade sobre o volume total da rocha (*bulk volume*), na Equação 1. O termo “porosidade” é usado incorretamente no lugar de “espaço de poro”, termo mais apropriado para descrever os vazios na rocha. O uso indevido desses termos muitas vezes leva à confusão, especialmente quando se fala sobre a origem da porosidade, sendo a origem do espaço dos poros, ou a história das alterações da porosidade (Lucia *et al.*, 2003).

$$\text{Porosidade} = \frac{\text{Volume de porosidade}}{\text{Volume total da rocha}} = \frac{\text{Volume total da rocha} - \text{Volume mineral}}{\text{Volume total da rocha}} \quad (\text{Equação 1})$$

A porosidade é uma propriedade de rocha importante porque é uma medida do volume potencial de armazenamento de hidrocarbonetos. A porosidade em reservatórios carbonáticos varia de 1 a 35%, os reservatórios do Pré-sal brasileiro apresentam porosidades efetivas entre 9 e 12%.

A porosidade efetiva, ou espaço de poro interconectado é usado para indicar a porosidade disponível para o fluxo de fluido. Esta propriedade é determinada através de análises laboratoriais e interpretação de lâminas delgadas. A interpretação das lâminas delgadas é uma estimativa, pois a quantidade de porosidade visual depende do método de observação, ou seja,

quanto maior a ampliação, maior o espaço dos poros visíveis. A porosidade é comumente estimada por inspeção visual usando um microscópio de baixa potência (Lucia *et al.*, 2003).

4.1.2. Permeabilidade

A permeabilidade (k) é uma propriedade da rocha, que corresponde com a capacidade do meio poroso transmitir fluidos e pode ser obtida desde a modelada desde a Lei de Darcy (Equação 2) com a medida em laboratório onde é encapsulada uma amostra de comprimento e diâmetro conhecidos em uma manga hermética (manga de Hasseler) em uma posição horizontal e um fluido de viscosidade conhecida é injetado (Lucia *et al.*, 2003).

$$Q = A \left(\frac{k}{\mu} \right) \left(\frac{\Delta P}{L} \right) \quad (\text{Equação 2})$$

Onde a k é a permeabilidade da rocha, μ é a viscosidade que corresponde a uma propriedade dos fluidos e $(\Delta p / L)$ é uma medida do potencial de fluxo.

Normalmente ar ou salmoura é usado como fluido e quando as taxas de fluxo podem ser mantidas, os resultados são comparáveis. Em taxas de fluxo baixas, a permeabilidade ao ar será maior que na salmoura, porque o gás não adere às paredes dos poros como o líquido. A permeabilidade é importante porque é uma propriedade da rocha relacionada à taxa de recuperação de hidrocarbonetos. Os valores variam consideravelmente de menos de 0,01 miliDarcy (mD) a mais de 1 Darcy. Uma permeabilidade de 0,1 mD é geralmente considerada o mínimo para a produção de petróleo (Lucia *et al.*, 2003).

4.1.3. Permeabilidade relativa

Petróleo, água e gás são encontrados em reservatórios em proporções variáveis. As medições de permeabilidade são normalmente feitas usando um fluido, geralmente ar ou água, e os valores de permeabilidade devem ser corrigidos para diferentes saturações de água, óleo e gás que ocorrem no reservatório. A correção é necessária porque quando um fluido não-umectante, como o óleo, entra em um sistema de poros úmidos, o óleo preenche os centros dos poros maiores e mais bem conectados, enquanto a água que se encontra fora as paredes e preenche os buracos poros menores (Lucia *et al.*, 2003).

Essa distribuição de fluido reduz o espaço de poro disponível para o fluxo de água ou óleo. Quando a água é injetada em um sistema de poros úmido com água, o óleo fica preso

nos poros menores devido às forças capilares, isso é conhecido como óleo residual de inundação de óleo para água (Figura 4). A simulação do fluxo de fluido é crítica e a alteração das características de permeabilidade relativa tem um efeito importante no desempenho esperado resultante (Lucia *et al.*, 2003).

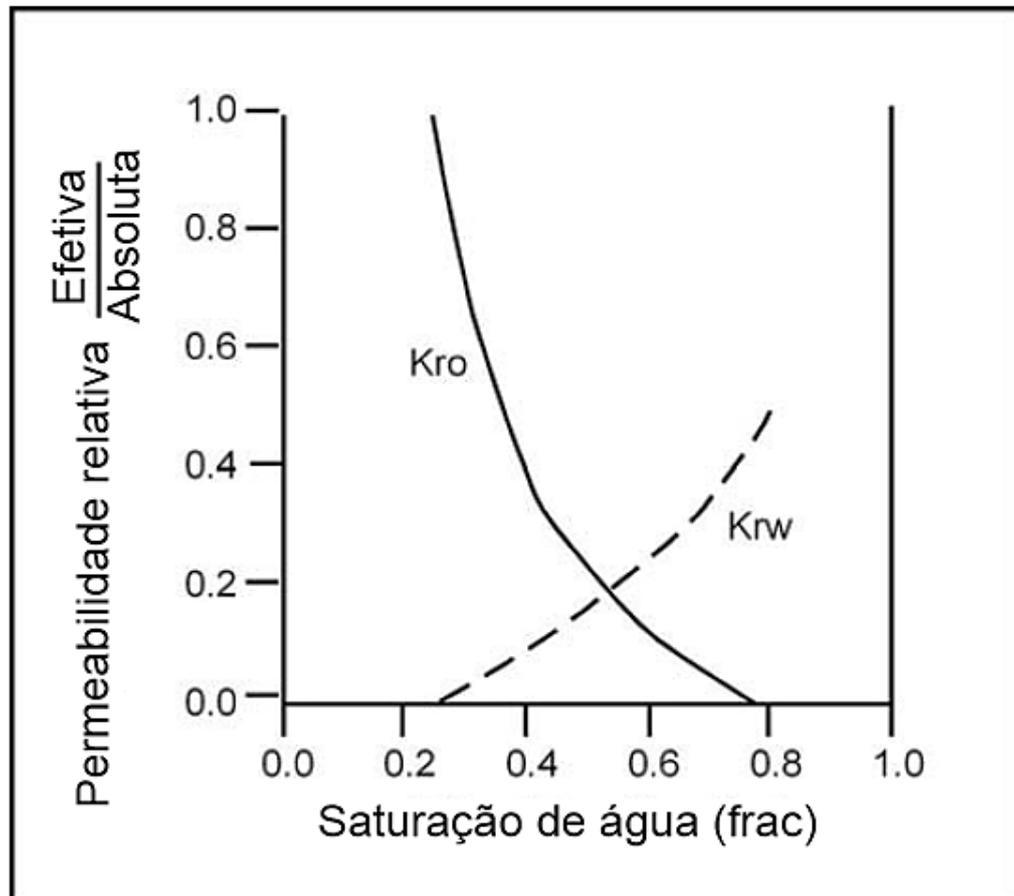


Figura 4. Gráfico de permeabilidade relativa. Kro é a permeabilidade relativa ao óleo e Krw é a permeabilidade relativa à água (modificado de Lucia *et al.*, 2003).

4.1.4. Tamanho de poros e saturação de fluidos

O tamanho dos poros é o fator comum entre a permeabilidade e a saturação de hidrocarbonetos. Modelos de permeabilidade descreveram o espaço de poro em termos de raio em tubos capilares. O número de capilares nos tubos foi equiparado à porosidade, então a permeabilidade é uma função da porosidade e do raio dos poros ao quadrado (Amyx, 1960). Kozeny substituiu o raio do poro pela área de superfície do espaço dos poros e desenvolveu a conhecida Equação de Kozeny que relaciona a permeabilidade à porosidade, área de superfície quadrada e constante de Kozeny (Kozeny, 1927).

A permeabilidade é geralmente estimada usando gráficos simples de permeabilidade-porosidade obtidos a partir de dados de petrofísica básica. No entanto, os gráficos cruzados de permeabilidade Vs porosidade para reservatórios carbonáticos mostra grande variabilidade petrofísica. As Equações 3 e 4, mostram que o tamanho dos poros e a distribuição do espaço dos poros, ou distribuição do tamanho dos poros, são importantes em toda a estimativa de permeabilidade (Lucia *et al.*, 2003; Figura 5).

$$k = \frac{\pi r^2}{32}, \text{ ou } k = \frac{\phi r^2}{8} \quad (\text{Equação 3})$$

$$k = \frac{\phi}{K_z S_p^2} \quad (\text{Equação 4})$$

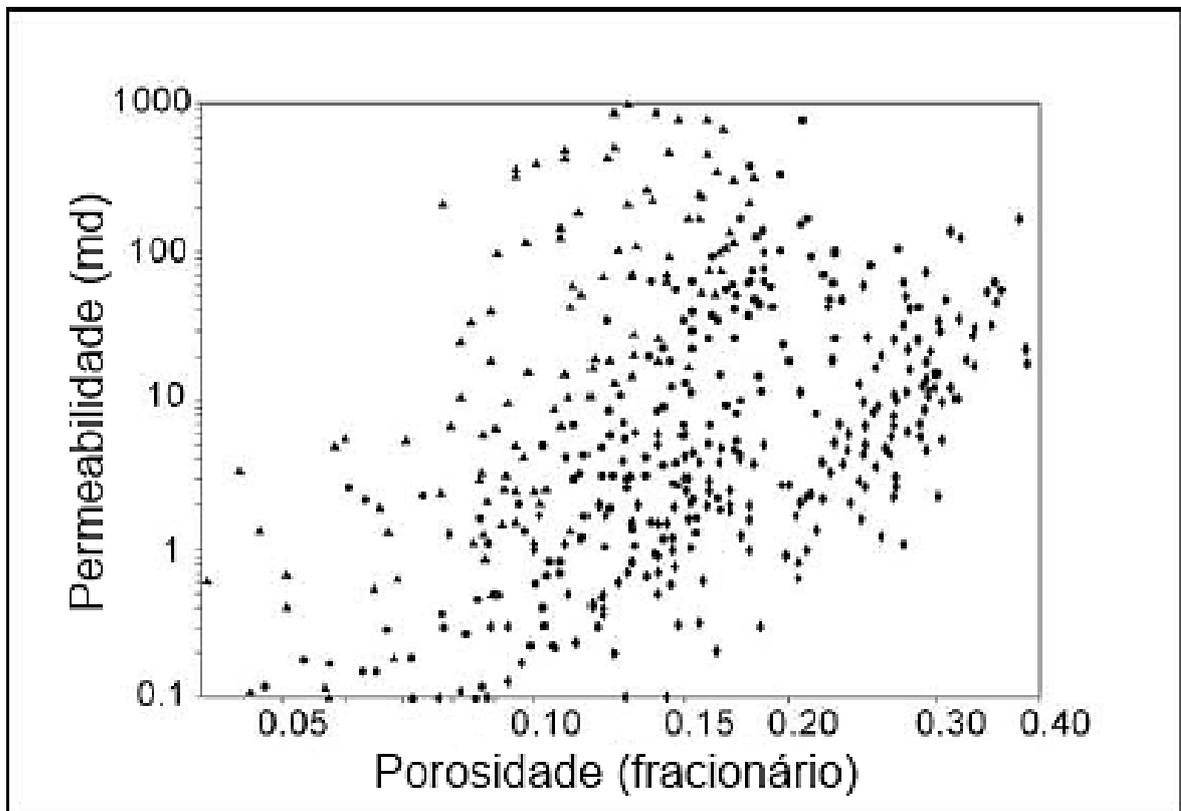


Figura 5. Gráfico de porosidade Vs permeabilidade para rochas carbonáticas (modificado de Lucia *et al.*, 2003).

4.1.5. Saturação

A saturação da água (S_w) é determinada usando a saturação irreduzível da água (S_{wi} , Equação 5), e abaixo deste contato é usada a Equação de Archie implementando a porosidade efetiva obtida pela Ressonância Magnética Nuclear (Equação 6).

$$S_{wi} = \frac{PHIT - FF}{PHIT} \quad (\text{Equação 5})$$

Onde:

PHIT: Porosidade total obtida pela Ressonância Magnética Nuclear.

FF: Fluidos livres obtidos pela Ressonância Magnética Nuclear.

$$S_w = \left(\frac{a \cdot R_w}{R_t \cdot \phi^m} \right)^{\frac{1}{n}} \quad (\text{Equação 6})$$

Onde:

a : fator de tortuosidade (valor de 1).

R_w : Resistencia média da água na zona aquífera (valor de 2,7).

R_t : Resposta do perfil de resistividade.

ϕ : Porosidade efetiva.

n : Exponente de saturação (valor de 2).

m : Fator de cementação (valor de 2).

A saturação de hidrocarbonetos em um reservatório está relacionada ao tamanho dos poros, pressão capilar e forças capilares. Para que o óleo se acumule em uma armadilha e gere sua deposição, a pressão na fase oleosa deve ser maior que a pressão na fase aquosa. Se a pressão do óleo for apenas ligeiramente superior à da fase aquosa, o raio de curvatura será grande e o óleo só poderá entrar nos poros dilatados (Lucia *et al.*, 2003; Figuras 6, 7 e 8).

Na natureza a diferença de pressão é produzida pela diferença entre a densidade da água e do óleo água e o óleo, o efeito de fluatibilidade. No nível de pressão capilar zero (P_{zcp}), a pressão do reservatório é igual à pressão na fase aquosa (P_w , Equação 7) (profundidade multiplicada pela densidade da água). Acima do nível P_{zcp} , a pressão na fase aquosa diminuirá pela altura acima do P_{zcp} multiplicada pela densidade da água (ρ_w) e a pressão na fase oleosa (P_o) diminuirá pela altura acima do P_{zcp} multiplicada pela densidade do óleo (ρ_o , Equação 8) (Lucia *et al.*, 2003).

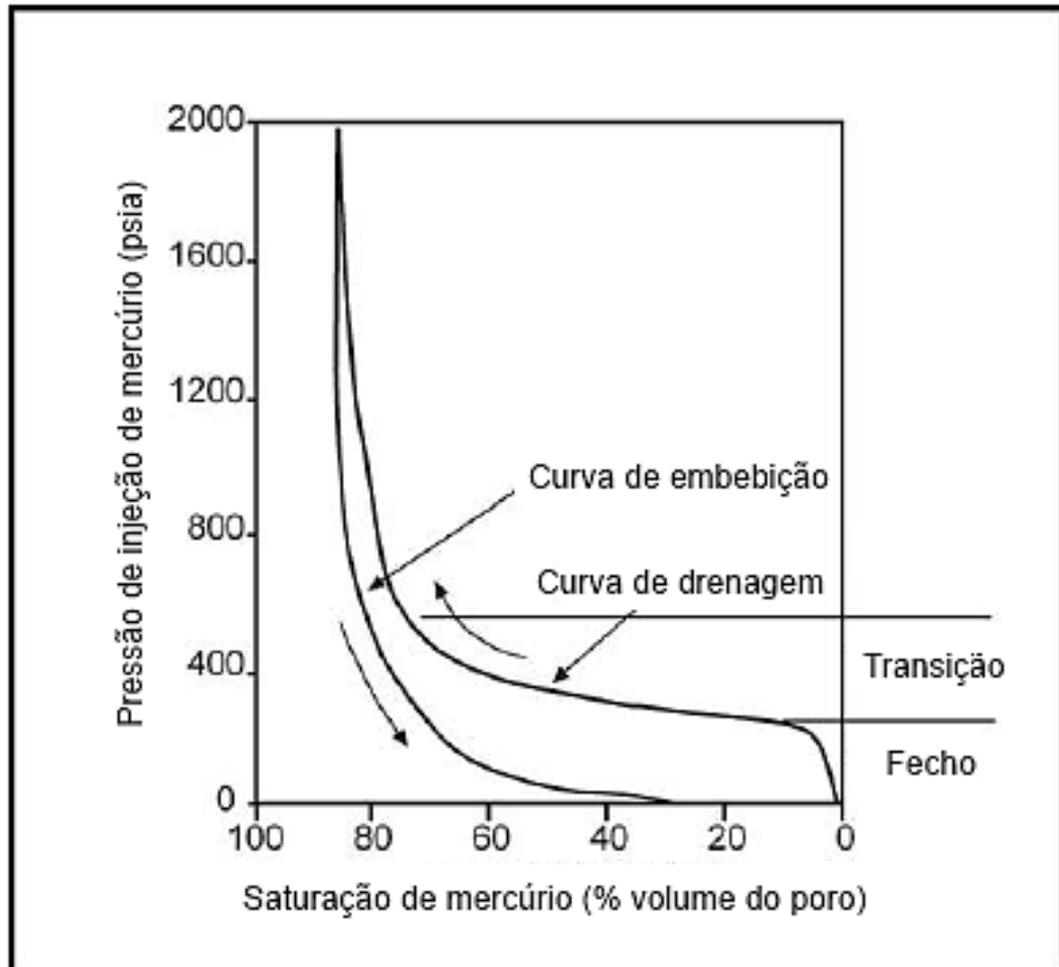


Figura 6. Curvas de pressão capilar típicas mostrando curvas de drenagem e embebição (modificado de Lucia *et al.*, 2003).

$$P_w = P_{zcp} - H\rho_w \quad (\text{Equação 7})$$

$$P_o = P_{zcp} - H\rho_o \quad (\text{Equação 8})$$

Em qualquer altura em uma coluna de óleo, a diferença de pressão entre a fase de óleo e a fase de água (pressão capilar) é a diferença entre a gravidade específica dos fluidos multiplicada pela altura da coluna de óleo (Equação 9).

$$P_o - P_w = 0.434H(\rho_w - \rho_o) \quad (\text{Equação 9})$$

Onde 0.434 é a unidade constante de conversão de pés de coluna de água para psi (Lucia *et al.*, 2003).

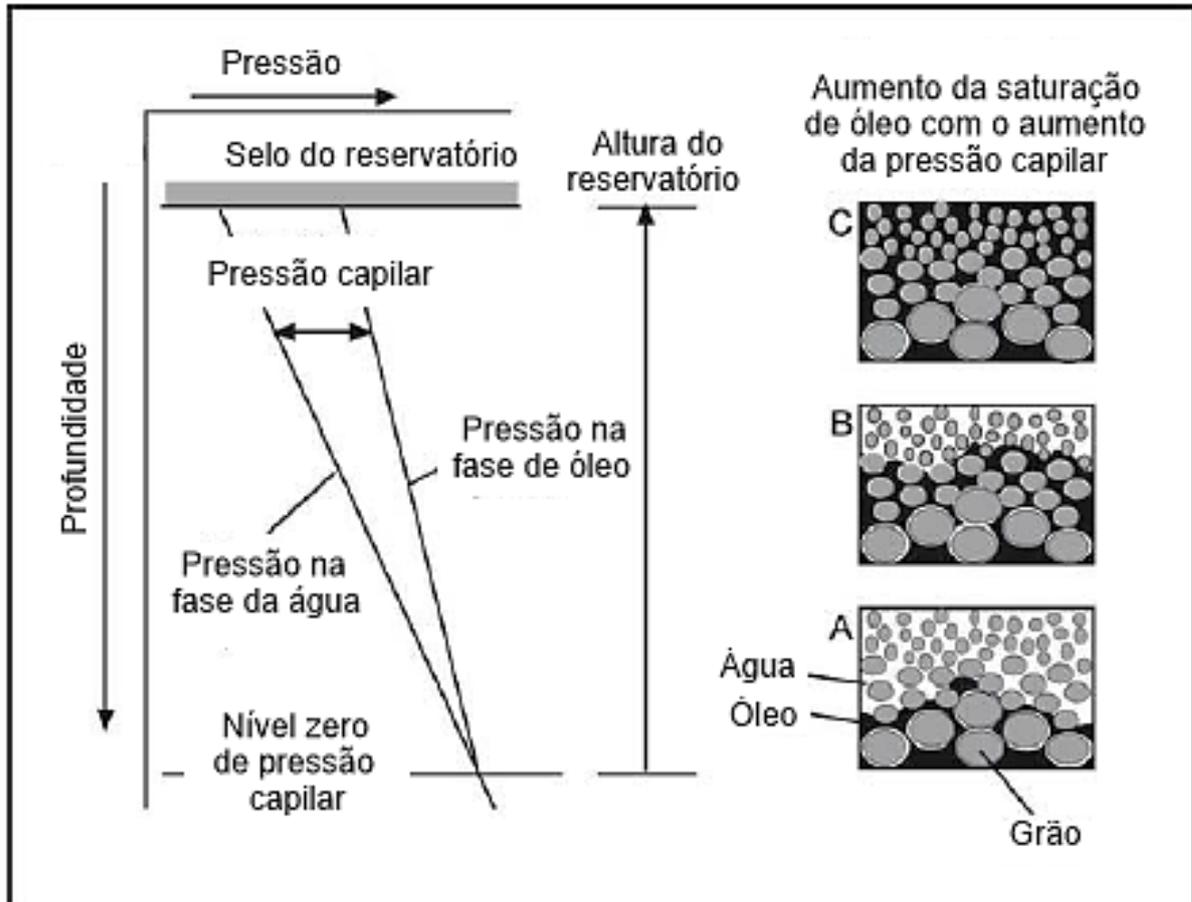


Figura 7. Diagrama mostrando poros menores sendo preenchidos com um fluido não umectante (óleo), deslocando um fluido umectante (água) conforme a pressão capilar aumenta linearmente com a altura do reservatório. Onde (A) Apenas o maior poro contém óleo na base do reservatório. (B) Poros menores são preenchidos com óleo conforme a pressão capilar e a altura do reservatório aumentam. (C) Os poros menores são preenchidos com óleo em direção ao topo do reservatório (modificado de Lucia *et al.*, 2003).

4.2. Estrutura do tipo de rocha

A distribuição espacial do tamanho dos poros na rocha está relacionada à estrutura das rochas. Perfis geofísicos, análise de testemunhos, dados de produção, testes de pressão e dados de amostra lateral fornecem medições quantitativas de dados petrofísicos na vizinhança do furo de poço, mas são geralmente dados unidimensionais (Figura 9). Portanto, os estudos que relacionam a estrutura da rocha com a distribuição do tamanho dos poros e propriedades do petróleo são fundamentais para a criação de modelos geológicos para a entrada em *softwares* de simulação (Lucia *et al.*, 2003).

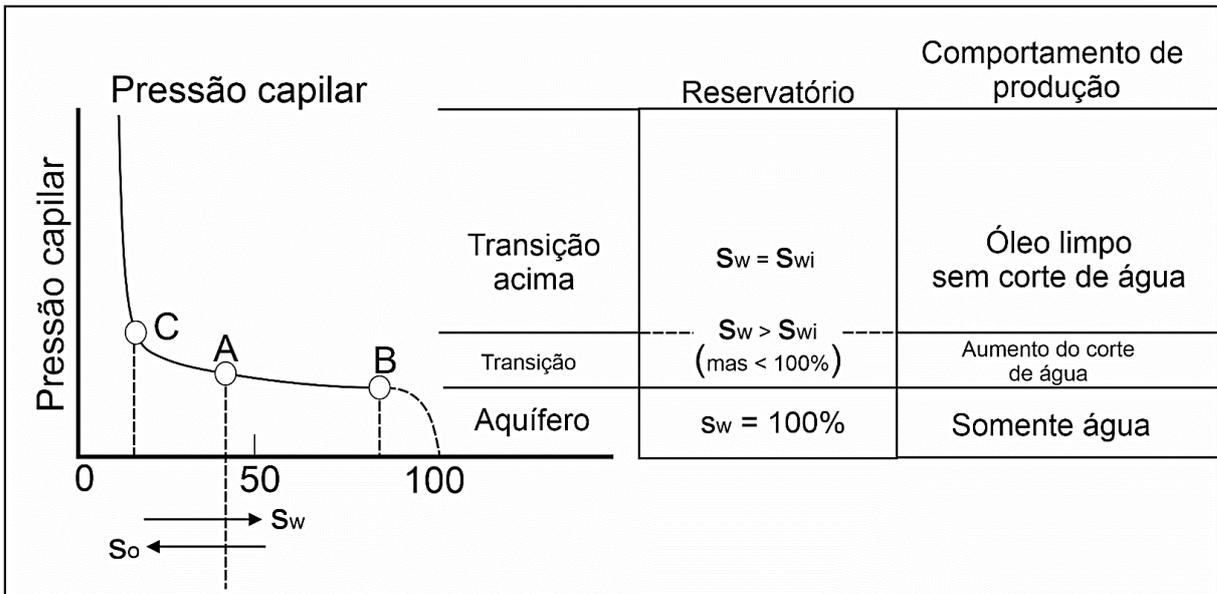


Figura 8. Comportamento da pressão capilar e saturação de água para diferentes zonas reservatórias (Crain, 2002).

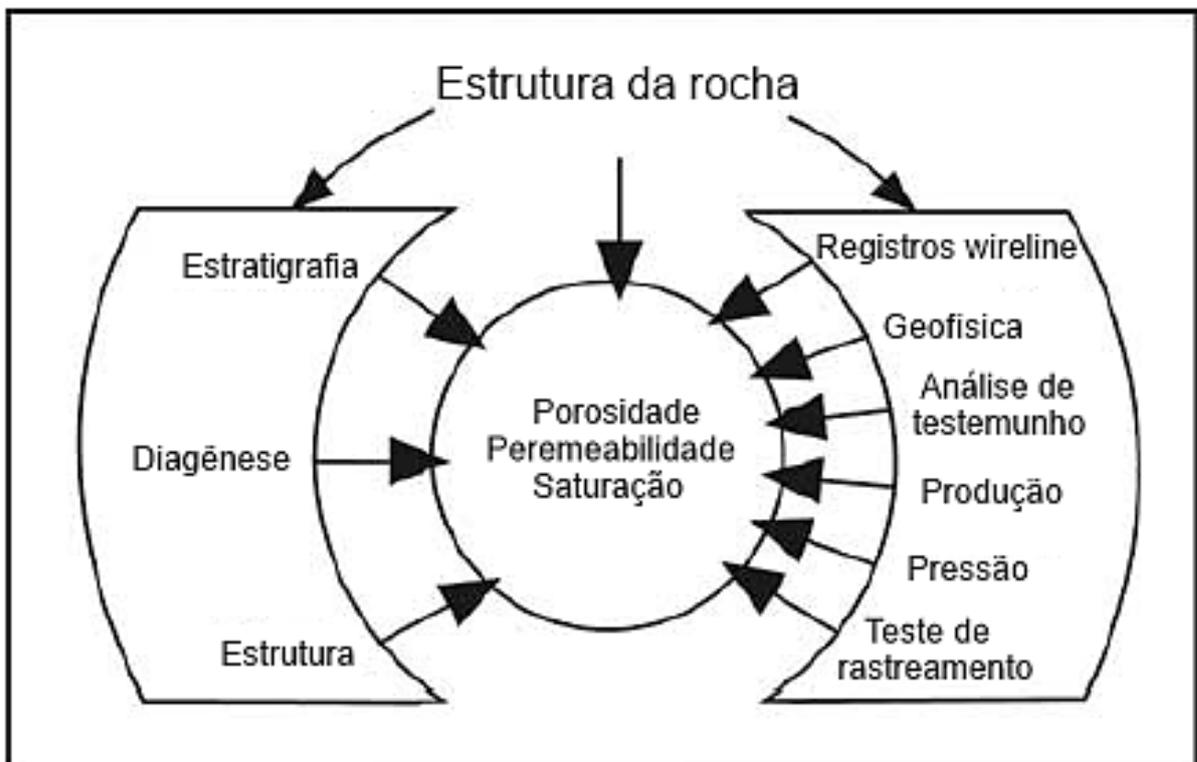


Figura 9. Integração de dados geológicos espaciais com dados de engenharia numérica por meio de estudos da estrutura rochosa (modificado de Lucia *et al.*, 2003).

4.3. Relação entre tipo de rocha e permeabilidade

4.3.1. Calcários

Os calcários possuem porosidade variável. Em lâminas delgadas, a distribuição do tamanho dos poros é controlada pelo tamanho do grão e a granulometria pelo cimento entre os grãos, que se reflete na quantidade de poros presentes (Lucia *et al.*, 2003). Exemplos de estruturas de rochas calcárias com pouco espaço poroso são ilustrados na Figura 10. Estruturas de *Grainstones* (Figuras 10A e 10B), o tamanho dos poros distribuição é controlada pelo tamanho do grão e classificação e pelo volume de cimento intergrãos, que se reflete na quantidade de porosidade interpartículas.

Em *Packstones* dominados por grãos, a distribuição do tamanho dos poros é controlada pelo tamanho dos grãos, pela quantidade de cimento e a quantidade de micrita intergranular (Figuras 10C e 10D). Em *Packstones*, *Wackestones* e *Mudstones* (Figuras 10E, 10F e 10G). O tamanho das partículas de Micrita e a quantidade de a porosidade interpartículas na lama controla a distribuição do tamanho dos poros. O tamanho de poro pequeno é referido como microporosidade e é visível com um microscópio eletrônico de varredura (SEM) (H).

Sendo necessário estabelecer que microporosidade corresponde com a parte do espaço do poro que tem uma dimensão característica inferior a 1 microm. Em geral, isto inclui não só poros muito pequenos, mas também a porosidade associada à rugosidade da superfície. A água neste espaço de poros faz parte da água capilar e da água de poros pequenos. Não se espera que a água nos microporos flua durante a produção. O termo é também definido como porosidade que não pode ser vista em ampliações inferiores a 50x (*SBL Glossary*).

4.3.2. Dolomita

A dolomitização pode alterar significativamente a estrutura da rocha. Se a rocha foi dolomitizada, entretanto, o cristal de dolomita frequentemente obscurece a estrutura de calcário precursor. Estruturas cristalinas precursoras delgadas dolomitizadas são facilmente reconhecíveis. No entanto, conforme o tamanho do cristal aumenta, as estruturas precursoras tornam-se progressivamente mais difíceis de determinar.

Os cristais de dolomita geralmente variam em tamanho de vários microns a mais de 200 microns. As partículas de variam de 20 microns à mais de 150 microns e o aumento do

crystal de dolomita resulta em um aumento ou diminuição proporcional no tamanho dos poros. A Figura 11 mostra exemplos de lâminas delgadas que apresentam dolomitização.

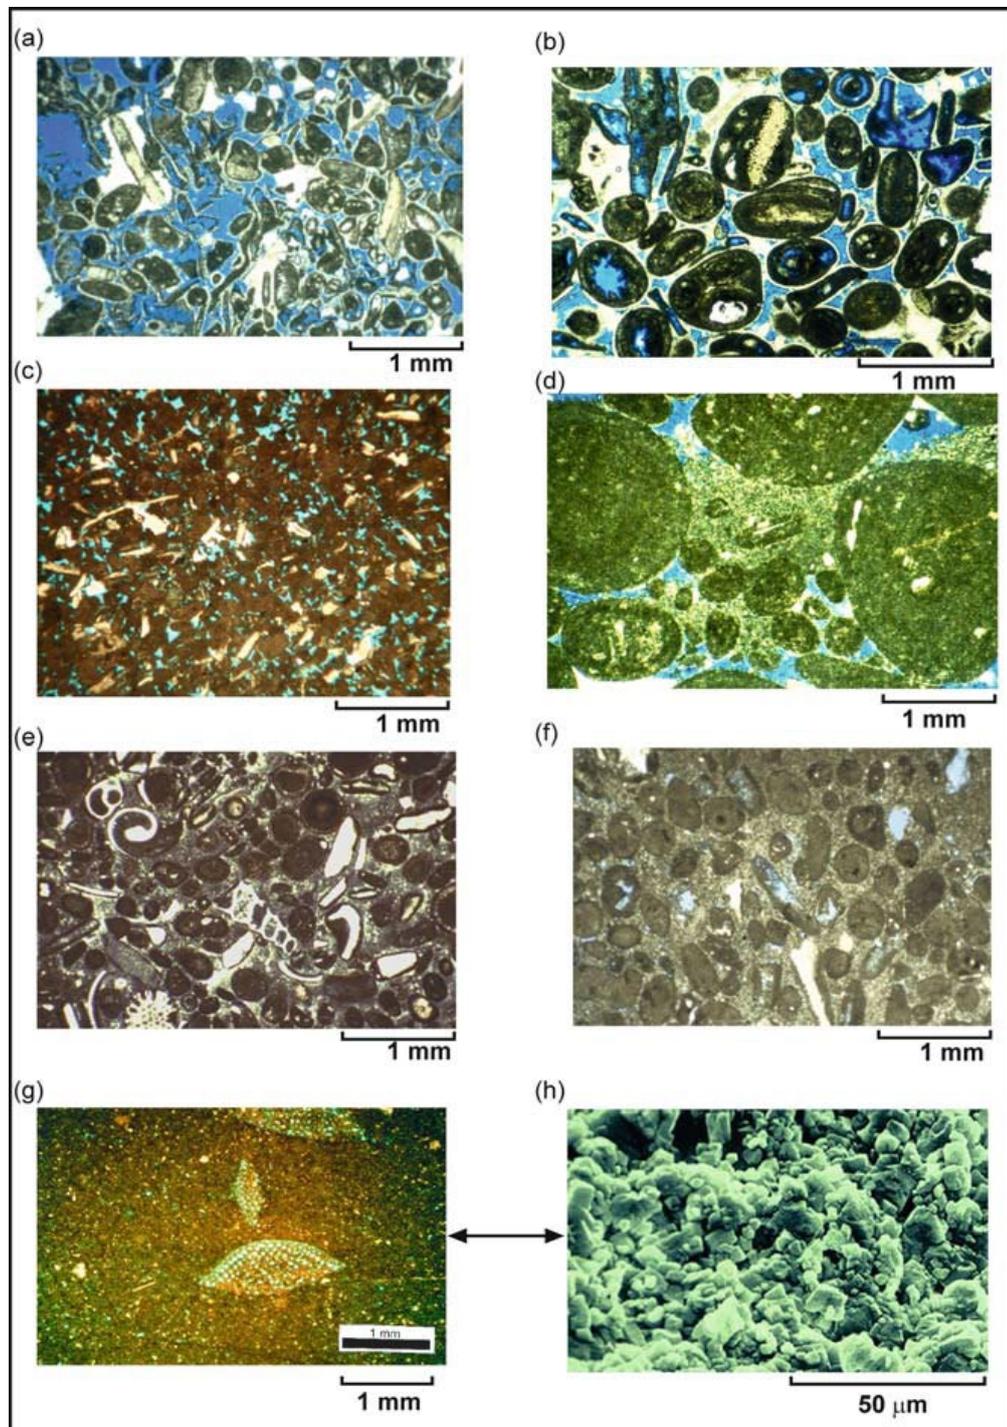


Figura 10. Exemplos de estruturas de rocha calcária não-vugulares. (a) *Grainstone*, (b) *Grainstone* com algum espaço poroso vug, (c) e (d) *Packstone*, (e) *Packstone* dominado por lama, (f) *Packstone* dominado com espaço poroso vug, (g) *Wackestone* com microporosidade e (h) Microporosidade em *Wackestone* – Imagem de SEM (Modificado de Lucia *et al.*; 2003).

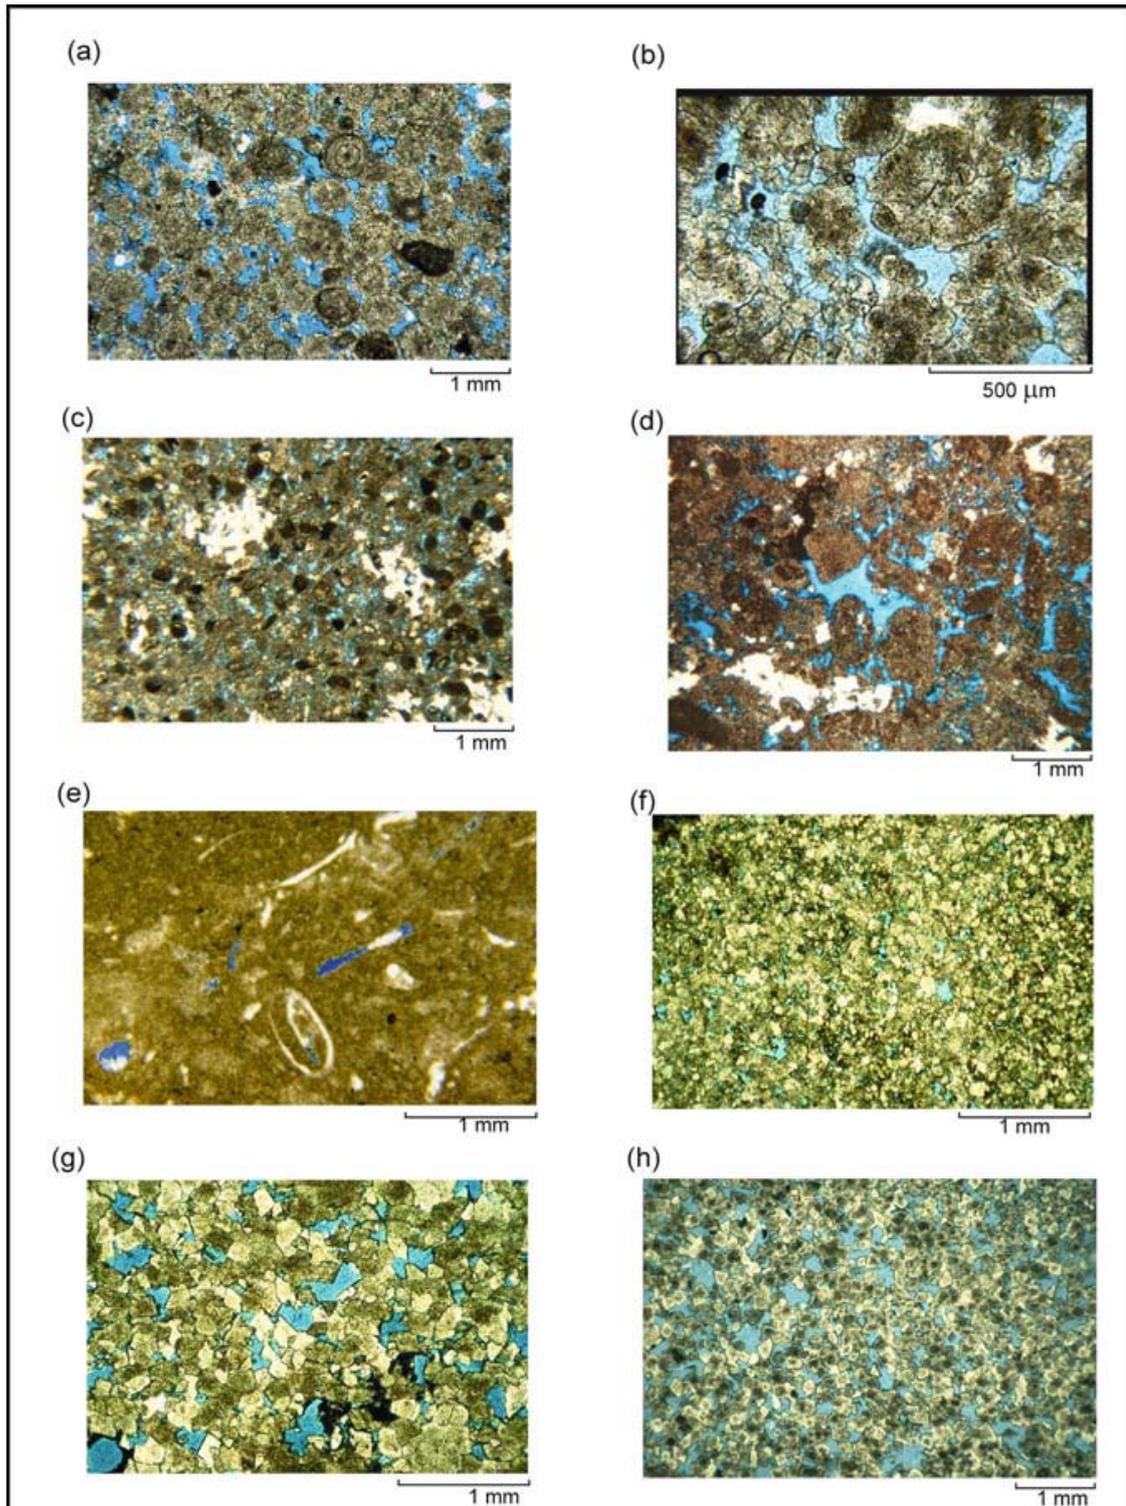


Figura 11. Estruturas de dolomitas não-vulgares. (a) Dolo-*Grainstone* com oóide cristalino tamanho médio. (b) Dolo-*Grainstone* cristalino tamanho grande. (c) *DoloPackstone* peloide fino cristalino tamanho médio dominado por grãos com anidrita poiquilotópica. (d) *DoloPackstone* granulado cristalino médio peloide com anidrita poiquilotópica (branco). (e) *DoloWackestone* cristalino fino. (f) *DoloWackestone* meio cristalino. (g) *DoloWackestone* cristalino grande. (h) Grande cristalino dolostone (Modificado de Lucia *et al.*; 2003).

4.4. Perfis de poço

O perfil de poço é uma representação digital ou analógica de uma propriedade física (resistividade, diâmetro do furo, densidade, porosidade, permeabilidade entre outros) medida em relação à profundidade. Essas medições são feitas por meio de diferentes ferramentas de registro (sensores) introduzidas no poço e conectadas através de um cabo à unidade de superfície permitindo a captura e processamento dos sinais de cada formação. Essas medições podem ser realizadas tanto em poço aberto quanto em poços com revestimento (Quijano, 2015).

4.4.1. Raios Gama (GR)

Este perfil geofísico é o registro da radioatividade natural das rochas, visto que os elementos radioativos (Urânio, Tório e Potássio) tendem a se concentrar em argilas e folhelhos, ou casos especiais de conglomerados líticos ou arcósios. É usado principalmente para fazer correlações entre poços, avaliações do conteúdo de argila de uma formação e análises minerais (Quijano, 2015). Arenitos e carbonatos sem argila têm baixas concentrações de material radioativo e fornecem leituras de Raios Gama. Quando o conteúdo de argila aumenta, a resposta aumenta da mesma forma, pois mais material radioativo seria encontrado. Já em arenitos limpos com alto teor de feldspato potássico, micas, glauconita ou água rica em urânio podem dar uma alta resposta no perfil (Quijano, 2015).

4.4.2. Volume de argila (Vsh)

O cálculo do volume de argila (Vsh) é útil para obter a saturação de água. Se o reservatório possui argila expansivas em sua estrutura (esmectita etc.), pode ter uma maior saturação de água, devido que este mineral pode-se inchar com água por causa de adsorção causada por carga elétrica negativa na superfícies dos argilominerais, o que aumenta a saturação de água. O volume de argila pode ser usado como indicador de áreas de interesse ou não; por exemplo, uma formação com alta teor de argila pode não ser classificada como um reservatório produtivo por causa de sua baixa permeabilidade.

Para determinar esse valor por meio de perfis, o mais utilizado é o modelo clássico areia-argila, pelo qual o volume de argila (Vsh) ou argilosidade é determinado através dos perfis de Raios Gama (GR) pode-se obter por meio da Equação 10 (Schlumberger, 1974).

$$V_{sh} = \frac{GR_{log} - GR_{sand}}{GR_{shale} - GR_{sand}} \quad (\text{Equação 10})$$

Onde GR_{log} é o valor lido do perfil, GR_{sand} é o valor normalizado para arenitos limpos e GR_{shale} é o valor normalizado para a resposta em argilas.

4.4.3. Perfis acústicos (DTC)

Os perfis sônicos mensuram propriedades acústicas, como o tempo de trânsito que uma onda sonora leva para percorrer o espaço entre dois detectores localizados a distâncias fixas entre si. A velocidade do som altera-se conforme o meio em que suas ondas se propagam, sendo maior em sólidos do que em líquidos e gases. Isso significa que quanto maior a velocidade de propagação, menor o tempo necessário para percorrer um mesmo caminho. Portanto, se considerarmos duas rochas semelhantes, a que contiver menos fluidos dentro de seu espaço poroso terá um tempo de trânsito menor. Por outro lado, as zonas de fraturas também podem ser identificadas devido a um maior tempo de trânsito do pulso para alcançar os receptores (salto de ciclo) devido ao acréscimo de porosidade secundária (Rodrigues, 2015).

4.4.4. Perfis de resistivades (RT)

Para determinar os verdadeiros valores de resistividade da rocha (RT) e a resistividade da área lavada (RXO), é necessário utilizar perfis de resistividade com diferentes diâmetros, razão pela qual várias curvas de resistividade são avaliadas, cuja principal diferença está no escopo de investigação de cada um deles.

Esses perfis são utilizados para determinar a saturação de água e hidrocarbonetos. Como a matriz das rochas ou grãos não são condutivas, a capacidade da rocha de transmitir uma corrente é uma função quase totalmente condicionada pela presença de água nos poros e sais dissolvidos. Os hidrocarbonetos, assim como a rocha e a matriz não são condutores. Portanto, quando a saturação dos hidrocarbonetos dos poros aumenta a resistividade da rocha também aumenta e a saturação da água diminui, enquanto nas áreas de água a resistividade será reduzida considerando sua salinidade (Quijano, 2015).

4.4.5. Perfis de Densidade (RHOB)

É um registro que tem como foco principal a emissão de Raios Gama de média energia que colidem com os elétrons da formação, perdendo energia e se espalhando ao atingir o detector, onde é feito uma contagem proporcional à densidade da rocha, permitindo caracterização da sua mineralogia (Bisbe, 2007). A resposta desta ferramenta é determinada pela densidade eletrônica da formação relacionando a densidade volumétrica real e depende da densidade da matriz rochosa, da porosidade da formação e dos fluidos que preenchem os poros (Bisbe, 2007).

4.4.6. Perfis Neutrão (NPHI)

É um registro de porosidade, cujo princípio é o bombardeamento da rocha com nêutrons que colidem com os núcleos de hidrogênio presentes nos poros da rocha e que são capturados pelo detector da ferramenta (Bisbe, 2007). A ferramenta de porosidade de neutrão é composta por um emissor e dois detectores, com os quais a porosidade é obtida diretamente, usando uma matriz pré-determinada (calcário, arenito ou dolomita). A determinação do volume de hidrogênio contido nos poros, proporcional à porosidade total, permitindo que essa propriedade seja calculada com bastante precisão (Bisbe, 2007).

4.5. Fácies

Um termo muito utilizado na caracterização de reservatórios é o da litofácies, sendo um tipo de rocha caracterizada dentro de um ambiente geológico pela sua composição mineralógica, arranjo textural, modelo deposicional (processos físicos, energia do ambiente de deposição e a acomodação de grãos em um substrato). Entretanto, não incluem na sua classificação textural os fenômenos diagenéticos que ocorrem nos grãos e entre os grãos, posteriores à deposição (processos químicos e mecânicos) (Serra e Abbott, 1982).

Quando é possível a extrapolação das litofácies individualizadas a todas as partes do reservatório utilizando perfis geofísicos de poços, assumem-se nomes como eletrofácies ou petrofácies, que podem representar as litofácies em seus ciclos deposicionais e, também, suas propriedades permoporosas avaliadas pelos perfis (Ellis & Singer, 2007).

Eletrofácies é o conjunto de respostas de perfis que caracteriza um sedimento e permite sua distinção dos demais (Serra, 1986). Devido à importância e aplicabilidade de estudos que contemplam a caracterização de eletrofácies e dados geológicos diretos, cada vez mais este tema vem sendo estudado na modelagem geológica de reservatórios (Schlumberger, 1987).

As petrofácies possuem a mesma definição que a eletrofácies, porém trata-se de uma descrição acrescida da caracterização de laboratório como ensaios de porosidade e permeabilidade a gás, pressão capilar e outros. As petrofácies devem caracterizar a geometria porosa, a saturação de

fluidos e sua distribuição em um determinado reservatório, classificada a partir de diversas medições petrofísicas. Ela pode identificar a estrutura porosa, conectividade e suas

particularidades com relação ao fluxo de fluidos. Também, relaciona as características permoporosas que resultam do controle deposicional (colapso mecânico do arcabouço, dissolução de grãos e/ou matriz e precipitação de material secundário), procurando identificar melhores e piores condições de armazenamento e fluxo de fluidos oriundos das rochas (Doveton,1994).

4.5.1. Classificação de litofácies

O diagrama triangular da Figura 12, mostra a classificação proposta que encapsula a gama de combinações principais onde não há evidência significativa de retrabalhamento. Fornecendo assim, categorias suficientes para diferenciar rochas de composição significativamente diferentes, o triângulo de classificação para depósitos no seu lugar original é subdividido em 9 tipos de rocha. A porcentagem de valores de corte (cut-offs) selecionados é aquela que fornecem uma separação conveniente de combinações comuns descritas em dados de testemunho e lâminas delgadas (Folk, 1959).

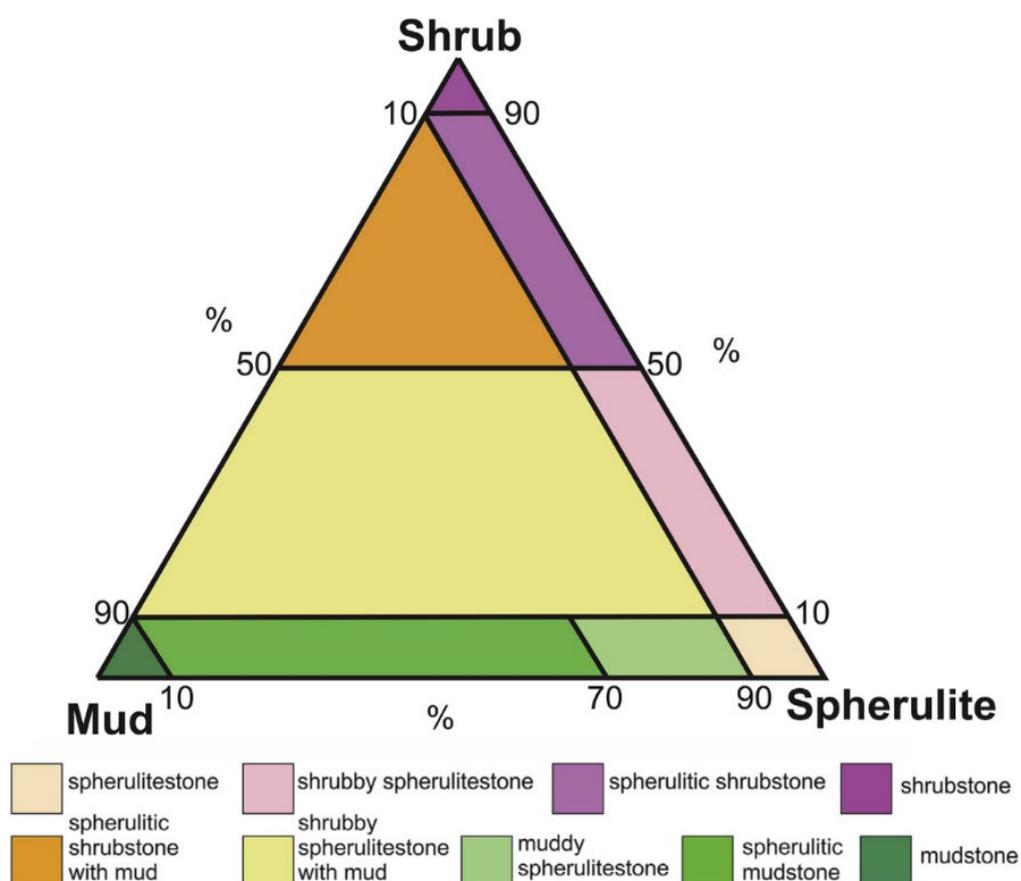


Figura 12. Diagrama ternário mostrando a classificação de litofácies para sedimentos gradados *in-situ* (Gomes *et al.*, 2020).

4.6. Algoritmos de aprendizagem de máquina

Os algoritmos de aprendizado de máquina (*Machine Learning*) são métodos que auxiliam a interpretação de dados petrofísicos ou qualquer outro tipo de dato, aproveitando o conhecimento do banco de dados aplicado aos dados de aquisição. Quanto mais dados são registrados, mais complexo e lento será o processamento de aprendizagem. As aplicações desses algoritmos permitirão um tempo de processamento e interpretação muito mais eficiente para a obtenção de resultados de classificação ou agrupamento precisos e consistentes (Wiyoga, 2021). O aprendizado de máquina aborda, por sua vez, uma série de questões que contribuem para problemas específicos, incluindo: problemas de classificação, associação, previsão, modelagem, entre outras muitas coisas. Os algoritmos de aprendizagem de máquina podem ser supervisionados ou não supervisionados (Sammut e Webb, 2011).

4.6.1. Algoritmos de aprendizagem de máquina supervisionados

O aprendizado de máquinas supervisionado é quando ensinamos ou treinamos o algoritmo usando dados que estão considerados como corretos. Basicamente, corresponde com aquele no qual o intérprete define as condições de contorno para o aprendizado da máquina, indicando referências sobre acerto e erro. Depois disso, a máquina recebe um novo conjunto de dados para que o algoritmo de aprendizado supervisionado analise os dados de treinamento (conjunto de dados de treinamento) e produza um resultado de agrupamento desde os dados inseridos como respostas corretas ou *input* de categorias (Izbicki *et al.*, 2020). Algoritmos supervisionados incluem: regressão, regressão logística, classificação, classificação Naive Bayes, vizinhos mais próximos (K Nearest Neighbors - KNN), Árvores de decisão e *Support Vector Machine (SVM)*.

4.6.1.1. *Support Vector Machine (SVM)*

Support Vector Machine (SVM) foi criado por Vladimir Vapnik em 1960, tem característica de ter dados de entrada em um espaço maior, gerando um hiperplano de separação maximizando a distância mínima do hiperplano aos dados da amostra ingerida mais próximo (Vapnik, 1998). Embora tenha sido originalmente desenvolvido como um método de classificação binária, sua aplicação foi estendida a problemas de classificação múltipla e regressão. Os *SVM* tornaram-se um dos melhores classificadores para uma ampla gama de situações, razão pela qual é considerado um dos mais importantes no campo do aprendizado estatístico e aprendizado de máquina.

Support Vector Machines são baseadas no Classificador de Margem Máxima, que por sua vez é baseado no conceito de hiperplano. Segundo Cortes e Vapnik (1995), o hiperplano

é considerado um plano que separa os dados de entrada, a distância do hiperplano e os vetores de suporte, que são os mais próximos do plano. Segundo James *et al.* (2013), “em um espaço p -dimensional, um hiperplano é um subespaço afim ao plano hiperplano de dimensão $(p - 1)$ ”. Por exemplo, em duas dimensões, um hiperplano é um subespaço plano unidimensional, ou seja, uma linha. Em três dimensões, um hiperplano é um subespaço bidimensional, ou seja, um plano. Em $p > 3$ dimensões é difícil visualizar um hiperplano, mas a noção de um subespaço plano $(p - 1)$ dimensional ainda se aplica.

Existem estratégias para melhorar o tratamento dos dados *SVM*. De acordo com (Boser, Guyon & Vapnik, 1992) pode-se usar o melhoramento do Kernel que consiste em que os conjuntos de dados são inseparáveis nas condições atuais, este melhoramento converte o conjunto de dados de entrada em um espaço dimensional superior e escolhe uma dimensão adequada, fazendo isso os conjuntos de dados tornam-se linearmente separáveis, portanto, classificáveis, demonstrando que o *SVM*, aplicando o melhoramento do Kernel é uma ferramenta eficiente e prática para resolver problemas lineares e não lineares (Amari & Wu, 1999).

Como exemplo, examinando a Figura 14, três observações de treinamento (pontos) são equidistantes do hiperplano da margem máxima e situam-se ao longo das linhas tracejadas indicando a largura da margem. Essas três observações são conhecidas como vetores de suporte, pois são vetores no espaço p -dimensional (na Figura 14 $p=2$). Curiosamente, o hiperplano de margem máxima depende diretamente dos vetores de suporte, mas não das outras observações (pontos). Portanto, um movimento para qualquer uma das outras observações não afetaria a separação hiperplano, desde que o movimento não cruzar o limite estabelecido pela margem (linhas tracejadas) (James *et al.*, 2013).

Na Figura 14 o hiperplano da margem máxima é mostrado como uma linha sólida. A margem é a distância da linha sólida a qualquer uma das linhas tracejadas. Os dois pontos azuis e o ponto roxo que se encontra nas linhas tracejadas são os vetores de suporte, e a distância desses pontos até a margem é indicada por setas. O grid roxo e azul indica a regra de decisão feita por um classificador com base nessa separação hiperplano (James *et al.*, 2000).

O *Support Vector Machine* de Kernel é uma extensão do suporte de vetor classificador que resulta da ampliação do espaço de características utilizando conjuntos de Kernel. A solução para o problema do vetor suporte classificador definindo uma série de

resolução de equações apresentadas e desenvolvidas na teoria de seu livro (Capítulo 9 - James *et al.*, 2013).

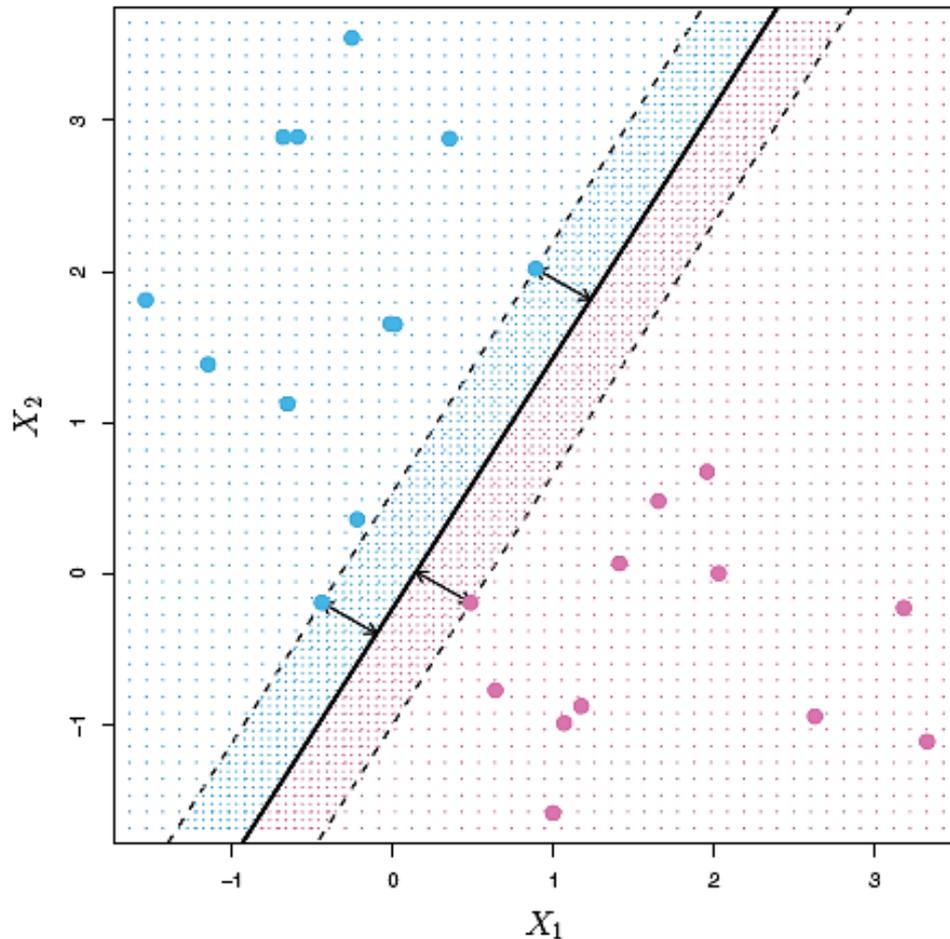


Figura 14. Duas classes de observações, mostradas em azul e em roxo (James *et al.*, 2013).

Para determinar *Linear Kernel Support Vector Machine (SVM Linear)* pode ser representado na Equação 11:

$$f(x) = \beta_0 + \sum_{i=1}^n \alpha_i \langle x, x_i \rangle \quad (\text{Equação 11})$$

Onde existem n parâmetros $\alpha_i, i = 1, \dots, n$, um por treinamento de observação. Para estimar os parâmetros $\alpha_1, \dots, \alpha_n$ e β_0 , tudo o que precisamos são os $\binom{n}{2}$ produtos internos $\langle X_i, X_i' \rangle$ entre todos os pares de observações de treinamento. (A notação $\binom{n}{2}$ significa $\frac{n(n-1)}{2}$ e dá o número de pares entre um conjunto de n itens.) Onde para calcular a função $f(x)$ calcula-

se o produto interno entre o novo ponto (x) e cada um dos treinamentos pontos (X_i) (James *et al.*, 2013).

Para a determinação do custo para o *Linear With Cost Support Vector Machine* (*SVM* com escolha de custo) Um argumento de custo nos permite especificar o custo de não sobrepassar à margem. Quando o argumento de custo é pequeno, então as margens serão amplas e muitos vetores de suporte estarão na margem ou superando a margem. Quando o argumento de custo for grande, as margens serão estreita e haverá poucos vetores de suporte na margem ou superando a margem (James *et al.*, 2013).

Um Kernel é uma função de Kernel que quantifica a similaridade de duas observações Equação 12 e 13.

$$K(X_i, X_i') \quad (\text{Equação 12})$$

$$K(X_i, X_i') = \sum_{j=1}^p X_{ij} X_{ij}' \quad (\text{Equação 13})$$

Onde K é alguma função a que nos referiremos como Kernel. A Equação 14 é conhecida como um Kernel linear porque o classificador de vetor de suporte é linear e apresenta características lineares, quantificando essencialmente a semelhança de um par de observações usando correlação de Pearson (padrão). Outro tipo de metodologia apresentada é Kernel *Support Vector Machine Polynomial* (*SVM* polinomial) onde para o *SVM* Linear um poderia substituir cada instância de $\sum_{j=1}^p X_{ij} X_{ij}'$ com a quantidade.

$$K(X_i, X_i') = \left(1 + \sum_{j=1}^p X_{ij} X_{ij}'\right)^d \quad (\text{Equação 14})$$

Conhecido como um Kernel polinomial de grau d, onde d é um inteiro positivo. Usando esse Kernel com $d > 1$. Trata-se de ajustar um vetor de suporte classificador em um espaço de dimensão superior envolvendo polinômios de grau d, em vez de no espaço original (Figura 15).

Um método adicional é *Linear Support Vector Machine on Radial Data* (*SVM* Radial), Equação 15.

$$K(X_i, X_i') = \exp\left(-\gamma \sum_{j=1}^p (X_{ij} - X_{ij}')^2\right) \quad (\text{Equação 15})$$

Onde γ é uma constante positiva (Figura 16).

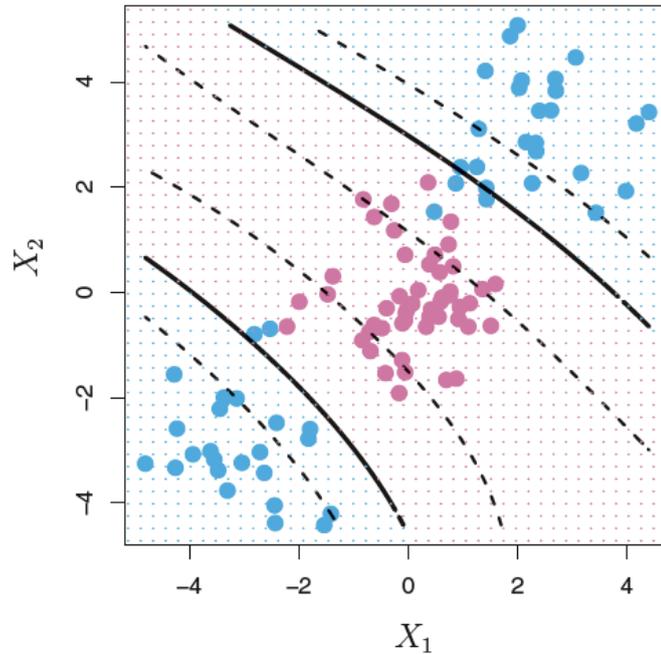


Figura 15. Exemplo de um Kernel Support Vector Machine Polinomial (SVM Polinomial) com um Kernel polinomial de grau 3 aplicado a dados não lineares (James *et al.*, 2013).

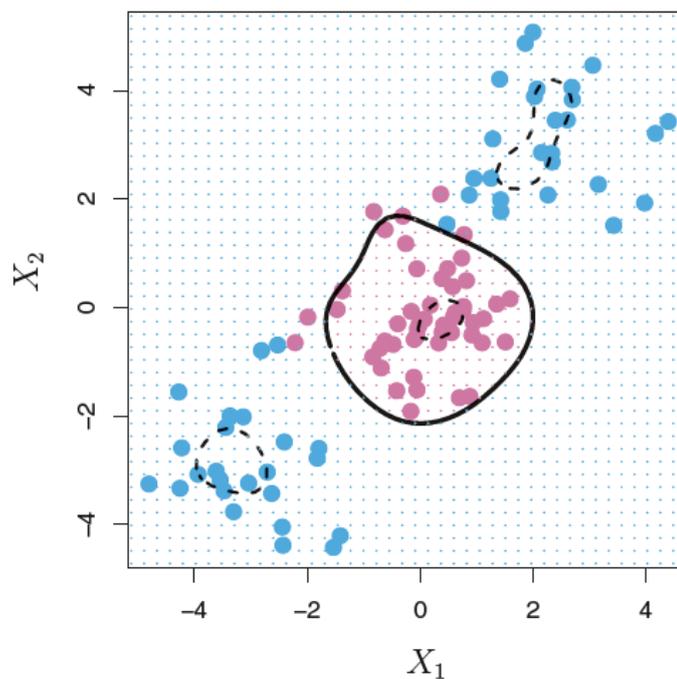


Figura 16. Exemplo de um Kernel Support Vector Machine Radial (SVM Radial) mostrando um agrupamento radial (James *et al.*, 2013).

4.6.2. Algoritmos de aprendizagem de máquina não supervisionados

O aprendizado não supervisionado é o treinamento de uma máquina usando informações que não são classificadas e não existem dados considerados como corretos, permitindo que o algoritmo atue sobre essas informações sem orientação. A tarefa do algoritmo é agrupar informações não classificadas de acordo com semelhanças, padrões e diferenças sem nenhum treinamento prévio de dados. Ao contrário do aprendizado supervisionado nenhum treinamento será dado à máquina. Portanto, a máquina fica restrita a encontrar a estrutura oculta em dados não rotulados por si mesma (Izbicki *et al.*, 2020).

Existem vários tipos de algoritmos de aprendizagem de máquina não supervisionados como: Hierarchical *Clustering*, *K-Means Clustering*, Principal Component Analysis, Singular Value Decomposition e Independent Component Analysis. Realçando que, nesta pesquisa foi implementada, unicamente, *K-Means Clustering*.

4.6.2.1. *K-Means Clustering*

K-Means é uma técnica de aprendizado de máquina não supervisionada que é bastante útil para agrupar dados exclusivos em vários grupos semelhantes (clúster) com base nos centros das variáveis independentes presentes no conjunto de dados. Alguns exemplos clássicos são agrupamento de diferentes tipos de clientes em programas de fidelidade da empresa ou separação dos pacientes médicos em categorias de risco baixo, médio, alto e extremo (Kabacoff, 2015).

A ideia básica do *K-Means* consiste em definir os agrupamentos de forma que a variação total dentro do grupo (conhecida como variação total dentro do agrupamento) seja minimizada. A partir de um conjunto de exemplos que queremos organizar em grupos, geralmente de acordo com uma noção de similaridade que é geralmente determinada por uma função de distância ou métrica. A proximidade entre exemplos determina se pertence ou não a um grupo, portanto, um elemento será mais semelhante ou terá maiores propriedades em comum com os elementos de seu grupo ou *Cluster* em relação aos elementos de características diferentes. Muitos dos métodos de aprendizagem de máquina dependem do cálculo de distâncias para estimar a semelhança entre dois exemplos considerando a estrutura dos dados (Verona *et al.*, 2016).

O agrupamento *K-Means Clustering* é uma abordagem simples para particionar um conjunto de dados em K *Clusters* distintos e não sobrepostos. Para executar *K-Means Clustering* se deve especificar o número desejado de *Clusters* K . O algoritmo *K-Means* atribuirá cada

observação a exatamente um dos K aglomerados. Se C_1, \dots, C_k representa um conjunto contendo os índices das observações em cada *Cluster*, os conjuntos satisfazem duas propriedades, equações 16 e 17.

$$C_1 \cup C_2 \cup \dots \cup C_k = \{1, \dots, n\} \quad (\text{Equação 16})$$

$$C_k \cap C_{k'} = \emptyset \text{ para } k \neq k' \quad (\text{Equação 17})$$

Respectivamente representam a observação de um dado que pertence pelo menos um dos K Clusters e quando nenhuma observação pertence a mais de um Cluster (James *et al.*, 2013).

4.7. Geoestatística

Na década de 1960, Matheron utilizou o termo Geoestatística e é conhecido como o pai de disciplina. E definiu esta como "a aplicação do formalismo de funções aleatórias para reconhecimento e estimativa de fenômenos naturais". A geoestatística é um ramo da estatística aplicada especializada na análise e modelagem de variabilidade espacial em ciências da terra. Seu objeto de estudo é análise e previsão de fenômenos no espaço e/ou tempo, tais como: lei do metal, porosidades, concentrações de um contaminante etc. (Díaz, 2002).

Atualmente, a geoestatística é um conjunto de técnicas utilizadas para analisar e prever valores de uma propriedade distribuídos no espaço ou no tempo. Em contraste com as estatísticas clássicas ou convencionais, tais valores não são considerados independentes. Para o caso contrário, eles são implicitamente considerados correlacionados entre si, ou seja, existe uma dependência espacial. Intuitivamente, isso indica que quanto mais próximo dois pontos estão localizados são mais correlacionados e quanto mais distantes há menos relação entre estes (Díaz, 2002).

A metodologia de Truncamento Gaussiano pode ser utilizada à regionalização das proporções de diferentes indicadores e os respectivos limiares aplicando para simulações de litofácies. Portanto, leva a simulações do tipo difusivo, no sentido de que as fácies i é cercado apenas pelas fácies $i - 1$ e $i + 1$. Segundo Díaz (2002), considera-se um indicador ou uma série de indicadores que se originam pela aplicação de um ou mais limiares para uma função aleatória gaussiana $Y(\underline{X})$ (Equação 18).

$$I_i(\underline{x}) = 1_{y_{i-1} < Y(\underline{x}) < y_i}, \text{ onde } -\infty = y_0 < y_1 < \dots < y_m = +\infty \quad (\text{Equação 18})$$

Os limiares (y_i) são escolhidos de tal forma que estão de acordo com as proporções (P_i) dos indicadores (Equação 19).

$$y_i = G^{-1}\left(\sum_{j=1}^i P_j\right) \quad (\text{Equação 19})$$

Uma vez que o diagrama de correlação da função aleatória gaussiana $Y(\underline{x})$ é conhecida, as funções de covariâncias diretas e cruzadas dos indicadores são conhecidas. A simulação de $I_i(\underline{x})$ se reduz à simulação de $Y(\underline{x})$ (um desenvolvimento mais teórico da metodologia é apresentado por Díaz (2002) em seu livro).

4.8. Atributos e filtros sísmicos

Os dados sísmicos precisam ser refinados porque as imagens sísmicas inicialmente apresentam muito ruído sísmico, dificultando uma correta interpretação. Esses filtros e atributos sísmicos ajudam a ter uma melhor visibilidade na hora de realizar a interpretação sísmica, ou seja, na interpretação de falhas geológicas, horizontes sísmicos, áreas de alta densidade de falhas naturais, corpos geológicos (cúpulas e canais salinos) (Cabrera & Rojas, 2019).

4.8.1. Dip Steering

Segundo Cabrera & Rojas (2019), trata-se de um atributo de rastreamento sísmico de refletores sísmicos baseado no pré-cálculo do campo de mergulho por *autotracking*, cujo princípio é a extração do mergulho e de azimute local traço a traço dos dados sísmicos, permitindo:

- Aprimoramento dos dados sísmicos 2D e 3D para o desenvolvimento de atributos de análise ao longo de eventos estratigráficos, aumentando ou diminuindo a suavização dos refletores sísmicos apresentados nas imagens, dependendo da melhor visualização da curvatura.
- A redução do ruído sísmico.
- A extração dos horizontes em função dos diferentes refletores sísmicos.

4.8.2. Dip Steered Median Filter (DSMF)

É um filtro para a melhoria lateral de eventos contínuos em função do Dip, através dos filtros de orientação estrutural que consegue se adaptar à orientação destes eventos, se reduz o ruído e aumenta a continuidade dos refletores. O DSMF é uma ferramenta que permite interpretar muito melhor os dados sísmicos e obter uma interpretação correta dos horizontes,

recolhendo as amplitudes num raio de investigação e substituindo-as pelo valor médio das amplitudes em um raio de pesquisa (Cabrera & Rojas, 2019).

4.8.3. *Fault Enhancement Filter (FEF)*.

É um filtro sísmico que permite a delimitação de falhas e fraturas ao longo do mergulho da estrutura, potencializando descontinuidades dos reflexos através da eliminação de ruídos. O atributo sísmico *FEF* é a entrada para atributos sísmicos de similaridade e coerência, fazendo delineamentos de descontinuidades geológicas em grande escala, como falhas ou feições estratigráficas (Gersztenkorn & Marfurt, 1999).

4.8.4. *Thinned Fault Likelihood (TLF)*

É um atributo sísmico desenvolvido para capturar, fornecer e delinear imagens sísmicas para a interpretação estrutural de falhas e fraturas em seções horizontais e verticais de uma área de estudo. O mergulho é varrido para a identificação das probabilidades relativas máximas de anomalias sísmicas que levam a falhas ou fraturas considerando:

- Mergulho máximo
- Alcance de varredura de azimute / mergulho

De modo, a determinar uma orientação da aparência de falhas, similaridade entre refletores sísmicos, variância calculada a partir da sísmica. O atributo sísmico *Thinned Fault Likelihood (TFL)* é usado para captura de falha e fratura de modo a melhorar as imagens sísmicas através de um filtro suavizado (Jaglan *et al.*, 2015).

5. Materiais e métodos

Este capítulo apresentará o fluxograma de trabalho que foi utilizado, onde são mostradas as diferentes sub-estágios dentro de cada estágio de trabalho e cada um deles será desenvolvido em detalhes ao longo deste capítulo (Figura 17).

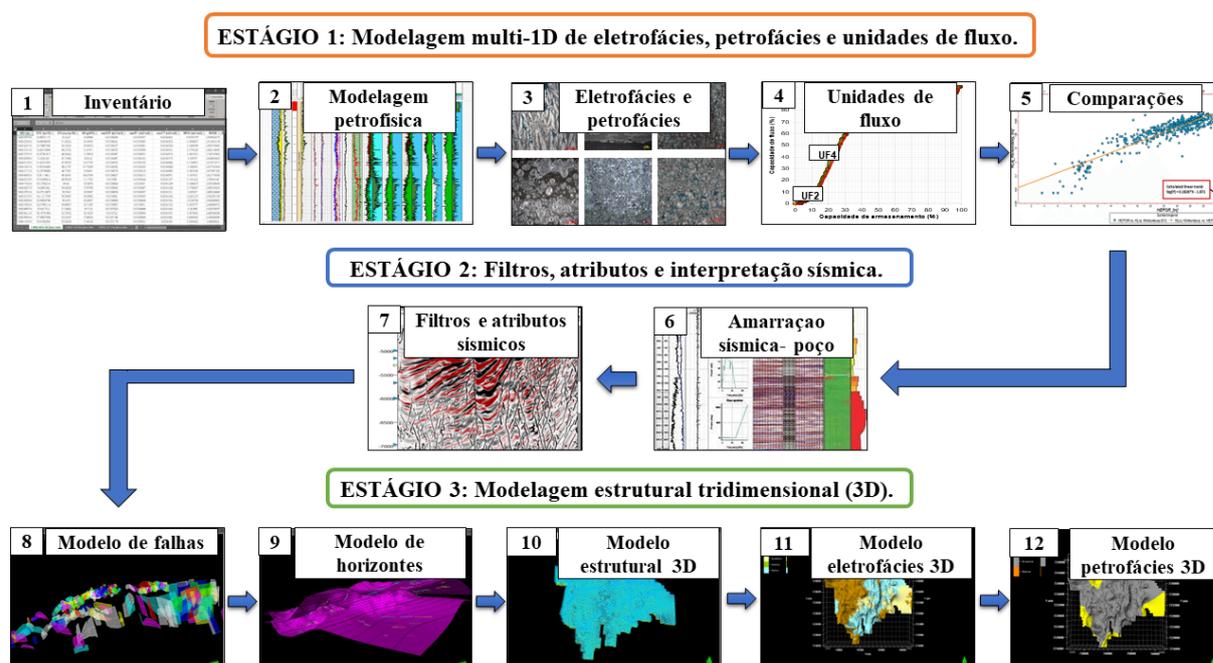


Figura 17. Fluxograma de trabalho implementado.

5.1. Estágio 1: modelagem multi-1D de eletrofácies, petrofácies e unidades de fluxo

5.1.1. Inventário de dados

Foram utilizados os conjuntos de dados fornecidos pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP): Campos de Berbigão, Sururu e Atapu do Pré-sal brasileiro para 19 poços (produtores e exploratórios).

Para os campos de Berbigão, Sururu e Atapu existem dados das seguintes categorias: dados de amostras laterais, dados petrofísicos convencionais e avançados, perfis de Ressonância Magnética Nuclear, espectroscopia mineral, litologia e zonas. É importante esclarecer que nem todos os poços continham a mesma quantidade de informações disponíveis, porém o inventário de informações foi feito na citada classificação. Análises de amostras laterais que permitem obter informações sobre densidade de grãos, permeabilidade horizontal

e porosidade efetiva, e análises de testemunhos de sondagem que permitem a obtenção dados sobre densidade de grãos, porosidade efetiva, permeabilidade horizontal e vertical.

Dados petrofísicos convencionais incluem raio gama (GR), bit size ou caliper (BS ou CAL), perfis sônicos compressionais e cisalhantes (DTC e DTS), porosidade Neutrão (NPHI), fator fotoelétrico (PEFZ ou PEF8), Densidade (RHOB) e resistividade em diferentes raios de pesquisa (RT20, RT60, RT90). Os perfis podem ter diferentes intervalos de amostragem entre os pontos onde a ferramenta leva os dados, deste modo é necessário que todos os perfis com o mesmo valor de passo ou espaçamentos sejam calibrados. O processo é denominado *Line Quality Control* (LQC), e para esta pesquisa foi implementado um passo de ferramenta de meio pé (0.1524 m) para homogeneizar o passo dos perfis.

Na categoria de perfis geofísicos especiais está o raio gama espectral que contém perfis separados de conteúdo de Urânio, Tório e Potássio. Além disso, também existem perfis de Ressonância Magnética Nuclear (RNM) permitem determinar a porosidade total, porosidade efetiva e fluidos livres, sendo extremamente úteis para calibrar modelos de porosidade e saturações dos carbonatos, pois a Ressonância Magnética Nuclear tem se mostrado uma ferramenta eficaz para a determinação desses dados.

A espectroscopia de captura elemental permite determinar a porcentagem de minerais presentes na formação de interesse, como anidrita, carbonato, argila, carbono, evaporita, pirita, siderita, quartzo, feldspato e micas. Estas categorias de dados são essenciais para a compreensão da litologia na área, permitindo assim uma descrição dos minerais mais representativos a uma determinada profundidade e servindo como informação adicional no estudo de registos geofísicos e como dados de validação para interpretação visual e estudo de lâminas delgadas.

5.1.2. Modelagem petrofísica

Os modelos petrofísicos gerados incluem porosidades, saturações de água e óleo. Para a determinação do volume de argila (Vshale), foram implementadas duas metodologias, utilizando o perfil de Raios Gama (GR) e perfis de densidade-neutrão (RHOB e NPHI). A geração dos modelos de porosidade total e efetiva a partir de 4 metodologias diferentes utilizando os perfis:

- Densidade (RHOB).
- Densidade-neutrão (RHOB e NPHI).
- Sônico (DTC).

- Sônico-neutrão (DTC e NPHI).

Para determinar saturações de água e hidrocarbonetos foram utilizadas 5 metodologias diferentes:

- Archie densidade.
- Archie densidade neutrão.
- Archie sônico.
- Archie sônico neutrão.
- Método de Crain (2002).

Para obter o modelo de permeabilidade, foi utilizado o modelo Timur-Coates (reportado nas informações fornecidas pela ANP), definido na Equação 20.

$$K = \left(\frac{\varphi}{C}\right)^m \left(\frac{1-S_{wi}}{S_{wi}}\right)^n \quad (\text{Equação 20})$$

5.1.3. Geração de eletrofácies e petrofácies através de algoritmos de aprendizagem de máquina

As litofácies foram classificadas desde a interpretação das lâmina delgadas de rocha, e posteriormente agrupadas em eletrofácies conforme o comportamento dos perfis geofísicos. Nesta caracterização das eletrofácies foi imprescindível a implementação de algoritmos de aprendizado automático para poder classifica-las. Vários cenários foram aplicados para avaliar a precisão do método de aprendizado utilizado pelo algoritmo otimizando assim o processo e obtendo a melhor eficiência e consistência no trabalho de classificação e previsão.

Considerando a classificação litológica de Gomes *et al.* (2020) e o esquema de Duham, 1962, Figuras 12 e 13 respectivamente, foram agrupadas as interpretações das lâminas delgadas em 10 categorias de litofácies: *Grainstone*, *Laminite*, *Muddy Spherulitestone*, *Mudstone*, *Packstone*, *Shrubby Spherulitestone with mud*, *Shrubstone*, *Spherulitestone*, *Spherulitic Mudstone* e *Spherulitic Shrubstone*. Porém, para a classificação das eletrofácies, ou seja, litofácies com base em comportamentos de resposta em perfis elétricos, foram estabelecidas 4 categorias de eletrofácies: *Mudstone-Laminite*, *Spherulitestone*, *Shrubstone* e *Grainstone*.

A metodologia de algoritmos de aprendizagem de máquina utilizou o *software* RStudio. Através do fluxograma de trabalho implementado apresentado na Figura 18 para a

geração das predições de eletrofácies foram utilizadas as 4 metodologias de *SVM* fornecidas por Kernel: *SVM* Linear, *SVM* Linear com escolha de custo, *SVM* Polinomial e *SVM* Radial. O *software* Microsoft Excel foi utilizado para a criação do conjunto de dados de entrada e os dados exportados dos perfis geofísicos comuns dos poços 2, 3, 7 e 8 tomados para o conjunto de treinamento e para o conjunto de validação na sua posterior predição.

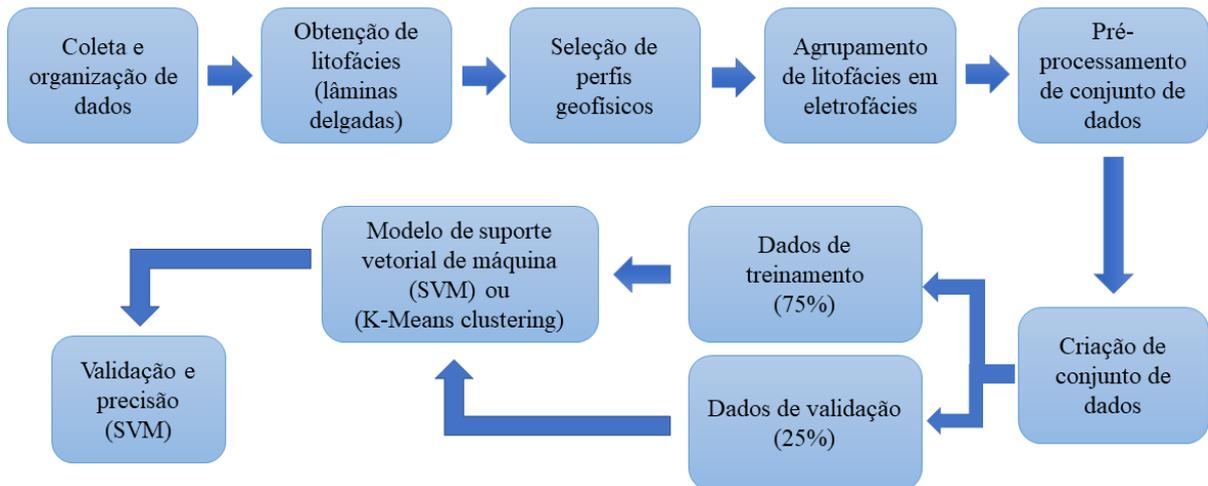


Figura 18. Fluxograma de trabalho de algoritmos de aprendizagem de máquina SVM e K-Means Clustering.

Para a geração de petrofácies é implementado o algoritmo *K-Means Clustering* utilizando como conjunto de entrada os dados petrofísicos de porosidade total, porosidade efetiva, fluidos livres, permeabilidade, saturação de água, deixando à livre escolha do *software* o número de *Clusters* recomendados para fazer uma correta classificação.

4.1.4. Geração de unidade de fluxo

Para a determinação das unidades de fluxo utilizou-se um conjunto de metodologias: Amaefule *et al.* (1993), Gunter *et al.* (1997), e Penna e Moreira, (2021). A metodologia de Amaefule é baseado no conceito de indicador de zona de fluxo (FZI, Equação 21).

$$0.0314 \sqrt{\frac{k}{\varphi_e}} = \left(\frac{1}{\sqrt{F_s \tau S_{vgr}}} \right) \frac{\varphi_e}{1 - \varphi_e} \quad (\text{Equação 21})$$

Onde:

K: Permeabilidade.

φ_e : Porosidade efetiva.

F_s : Fator de forma.

τ : Tortuosidade dos poros.

S_{vgr} : Área de superfície específica por unidade de volume de grãos.

Da Equação 22 são consideradas as equações 23, 24 e 25.

$$RQI = 0.0314 \sqrt{\frac{k}{\varphi_e}} \quad (\text{Equação 22})$$

$$(\varphi_z) = \frac{\varphi_e}{1 - \varphi_e} \quad (\text{Equação 23})$$

Onde:

(φ_z) : Porosidade normalizada.

$$FZI = \left(\frac{1}{\sqrt{F_s \tau S_{vgr}}} \right) \quad (\text{Equação 24})$$

Portanto, FZI pode-ser definida como a relação entre o Índice de qualidade do reservatório com a porosidade normalizada $\left(\frac{RQI}{\varphi_z} \right)$.

Segundo Gunter *et al.* (1997), é utilizado um gráfico estratigráfico modificado de Lorenz (SMLP), o qual apresenta uma porcentagem capacidade de fluxo cumulativo horizontal (K_H , Equação 25) Vs a capacidade de armazenamento cumulativa (φ_H) encomendada em sequência estratigráfica, a fim de definir unidades de fluxo petrofísicos dentro poços.

$$K_H = K_1(H_1 - H_2) + K_2(H_2 - H_3) + \dots + K_i(H_i - H_{i+1}), \dots \dots \dots \quad (\text{Equação 25})$$

Onde:

$H_i - H_{i+1}$: A diferença de profundidade entre as amostras subsequentes i e $i + 1$. Portanto para o cálculo da capacidade de armazenamento cumulativa (φ_H) se utiliza a Equação 26.

$$\varphi_H = \varphi_1(H_1 - H_2) + \varphi_2(H_2 - H_3) + \dots + \varphi_i(H_i - H_{i+1}), \dots \dots \dots \quad (\text{Equação 26})$$

A variação de inclinação nos segmentos do *plot* K_H Vs φ_H é interpretado como as principais unidades de fluxo no conjunto de dados.

Para a geração do gráfico de discretização das unidades de fluxo horizontal se utiliza o fluxo de trabalho descrito por Penna e Lupinacci (2021). Devido as diferenças de escala entre os dados de testemunho e dos perfis de poço e os dados sísmicos, a tipagem de rochas RQI/FZI usando percentis de valores e uma curva S cumulativa de dados de permeabilidade/porosidade do testemunho:

- Calcular os percentis de porosidade e permeabilidade do conjunto de dados principal
- Calcular os valores de RQI e FZI usando as equações (21) e (23) e os valores dos percentis.
- Ordenar os dados com valores crescentes de $\log(FZI)$.
- Acumular e normalizar os percentis dos valores de permeabilidade horizontal.
- *Plotar* os percentis de valores de permeabilidade horizontal acumulados e normalizados Vs os valores de $\log(FZI)$, obtendo os dados de inclinação da curva para cada amostra.

5.2. Estágio 2: filtros, atributos e interpretação sísmica

5.2.1. Amarração sísmica-poço

O processo de amarração sísmica-poço é um método no qual os perfis de Densidade (RHOB) e velocidade de onda compressional (VP), calibrados com a relação tempo-profundidade obtida através de dados de *check-shots* e VSP. Os perfis são ajustados para valores de velocidade mais reais. Após a obtenção da impedância acústica os coeficientes de reflexão são obtidos, indicando onde as mudanças litológicas são encontradas nas diferentes camadas do subsolo. Posteriormente, é gerado uma *Wavelet* que acomoda os diferentes coeficientes de reflexão gerando assim um traço sintético do poço. Isso é feito de modo a acomodar ou agrupar este traço sintético nos diferentes traços sísmicos obtidos pelos refletores para poder ter uma continuidade das diferentes camadas entre a sísmica e o poço. Ou seja, uma vez que os dados do poço são recolhidos em profundidade, são convertidos em termos de tempo tal como a sísmica podendo assim trabalhar com todas as informações nos mesmos parâmetros e obter resultados de interpretação constantes.

5.2.2. Filtros e atributos sísmicos

O processamento sísmico realizado nas imagens sísmicas obtidas dos volumes sísmicos em cada um dos cortes, inicialmente é aplicado o *Dip Steered Median Filter (DSMF)*, um filtro sísmico que ajuda a reduzir o ruído e aumenta a continuidade dos refletores, posteriormente o *Fault Enhancement Filter (FEF)* que auxilia na delimitação e interpretação

de falhas e fraturas. Por fim é aplicado o *Thinned Fault Likelihood (TFL)* que é um atributo sísmico que gera uma melhoria na Imagens sísmicas por meio de filtro de suavização, separando do ruído as falhas e fraturas mais relevantes.

É importante ressaltar que os ângulos de inclinação que melhor representam as falhas para a aplicação do suavização foram modificados, levando-se em consideração que quando se trata de falhas inversas este ângulo deve ser $<45^\circ$, portanto, funciona nas faixas de 20 a 45° . As imagens são sobrepostas aplicando *Fault Enhancement Filter (FEF)* e *Thinned Fault Likelihood (TFL)* de forma a conseguir uma melhor continuidade nos refletores e obter uma melhor interpretação das falhas e horizontes.

5.2.3. Interpretação sísmica

No sub-estágio de interpretação de falhas e horizontes analisa-se os dados sísmicos e identificar discordâncias nas camadas geológicas (falhas) ou as interfaces entre as diferentes camadas. A interpretação sísmica foi realizada no Petrel, considerando um espaçamento de 12.5 m para as *in-lines* e de 25 m para as *crosslines*.

Foram identificados os horizontes correspondentes os topos das formações Barra Velha e a Formação Itapema. Devido à grande quantidade de ruído e a baixa qualidade da sísmica, aplicou-se o fluxograma de trabalho proposto por Cabrera e Rojas (2019) para a definição de atributos e filtros sísmicos, além de ter umas respostas fracas nos refletores, passamos a gerar *crosslines* entre os diferentes poços, nos quais os topos das formações foram identificados para uma propagação de horizontes muito mais contínua ao longo da sísmica.

5.3. Estágio 3: modelagem estrutural 3D

5.3.1. Modelo estrutural 3D

O modelo de falhas e o modelo de horizontes foram usados para criar o modelo estrutural, criando o esqueleto da Malha 3D do modelo estrutural da área delimitada por o polígono dos campos Berbigão, Sururu e Atapu.

5.3.2. Geoestatística

O procedimento de aplicação da geoestatística ao modelo estrutural para propagação de eletrofácies, é feito no *software* PETREL. Além da geração do raio de anisotropia da propagação, o qual é calculado como uma distância média das distâncias entre poços. Um processo de aumento de escala de propagação é realizado, começando no nível do

poço, depois na escala de tamanho de malha criada para o modelo estrutural e, finalmente, propagando-se por todo o volume do modelo estrutural. Para a modelagem de reconstrução de eletrofácies e petrofácies 3D foi utilizado método de Simulação Gaussiana Truncada (Beucher e Renard, 2016; Ferreira e Lupinacci, 2018; Peçanha *et al.*, 2019), ao ser eficiente nos resultados gerados.

6. Resultados

6.1. Estágio 1: modelagem multi-1D de eletrofácies, petrofácies e unidades de fluxo

6.1.1. Inventário de dados

Neste primeiro estágio foi realizado um inventário de todos os dados fornecidos pela ANP, com o objetivo de classificar as informações conforme descrito no capítulo 4.1.1. Oito (8) poços preencheram os requisitos mínimos de informação necessários para a realização deste projeto. As informações de poço abrangem o intervalo entre a base do sal e a perfuração total do poço (TD). Os dados de poço foram delimitados para a formação de interesse neste trabalho, a Formação Barra Velha, na Figuras 19, 20, 21, 22, 23, 24, 25 e 26.

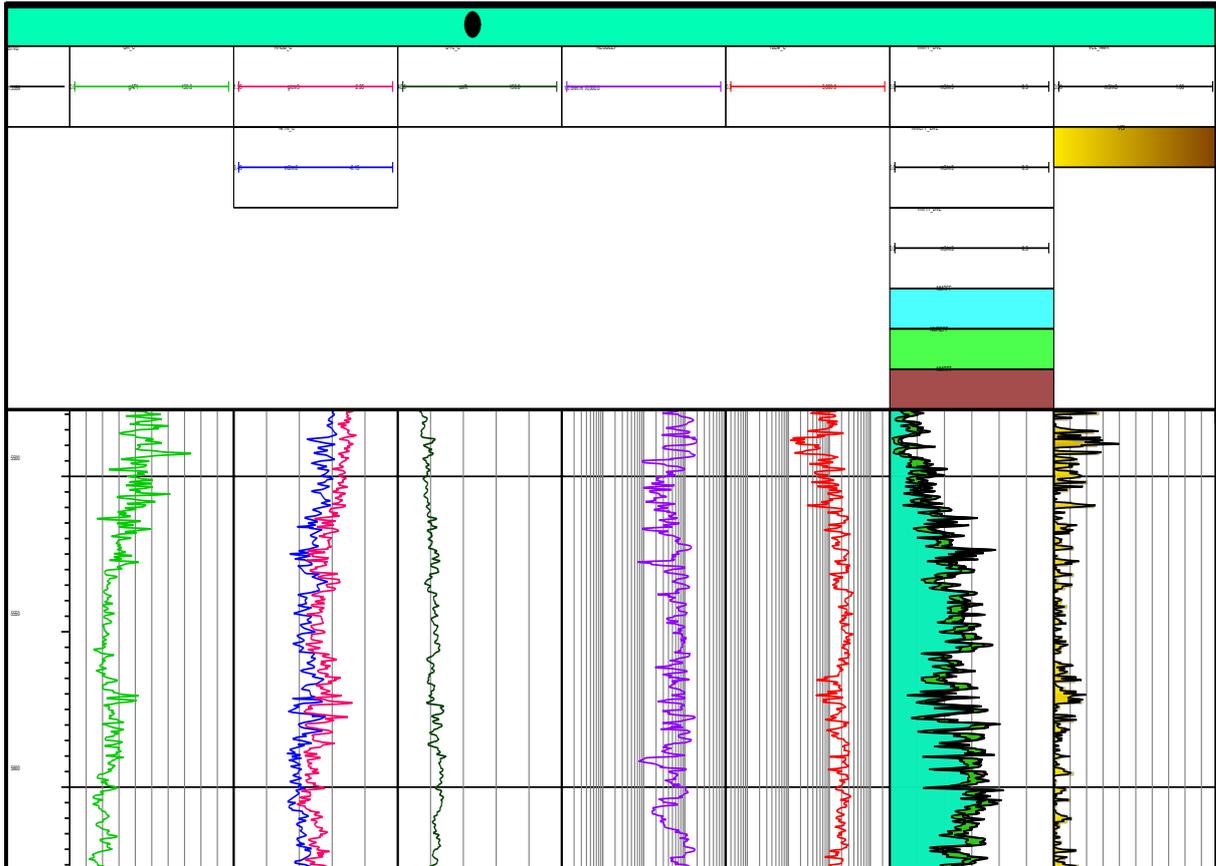


Figura 19. Perfis geofísicos no poço 1 (1-BRSA-618-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

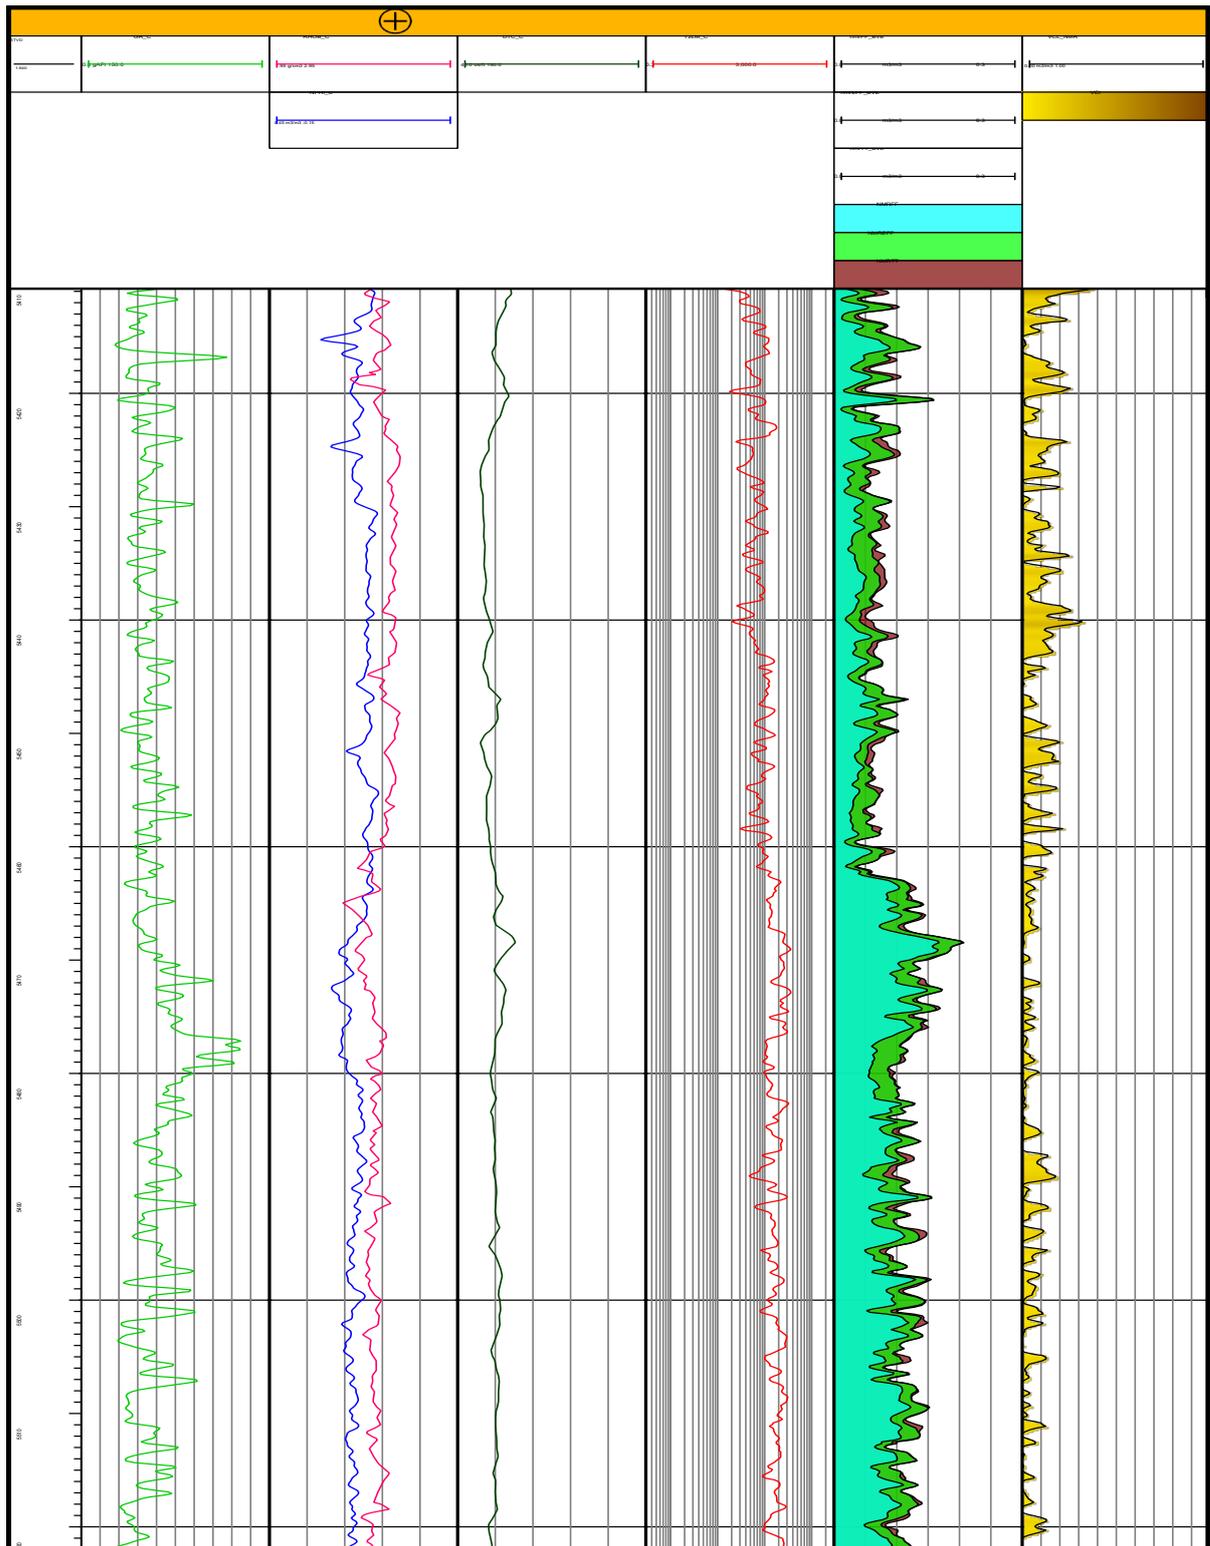


Figura 20. Perfis geofísicos no poço 2. (3-BRSA-891A-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

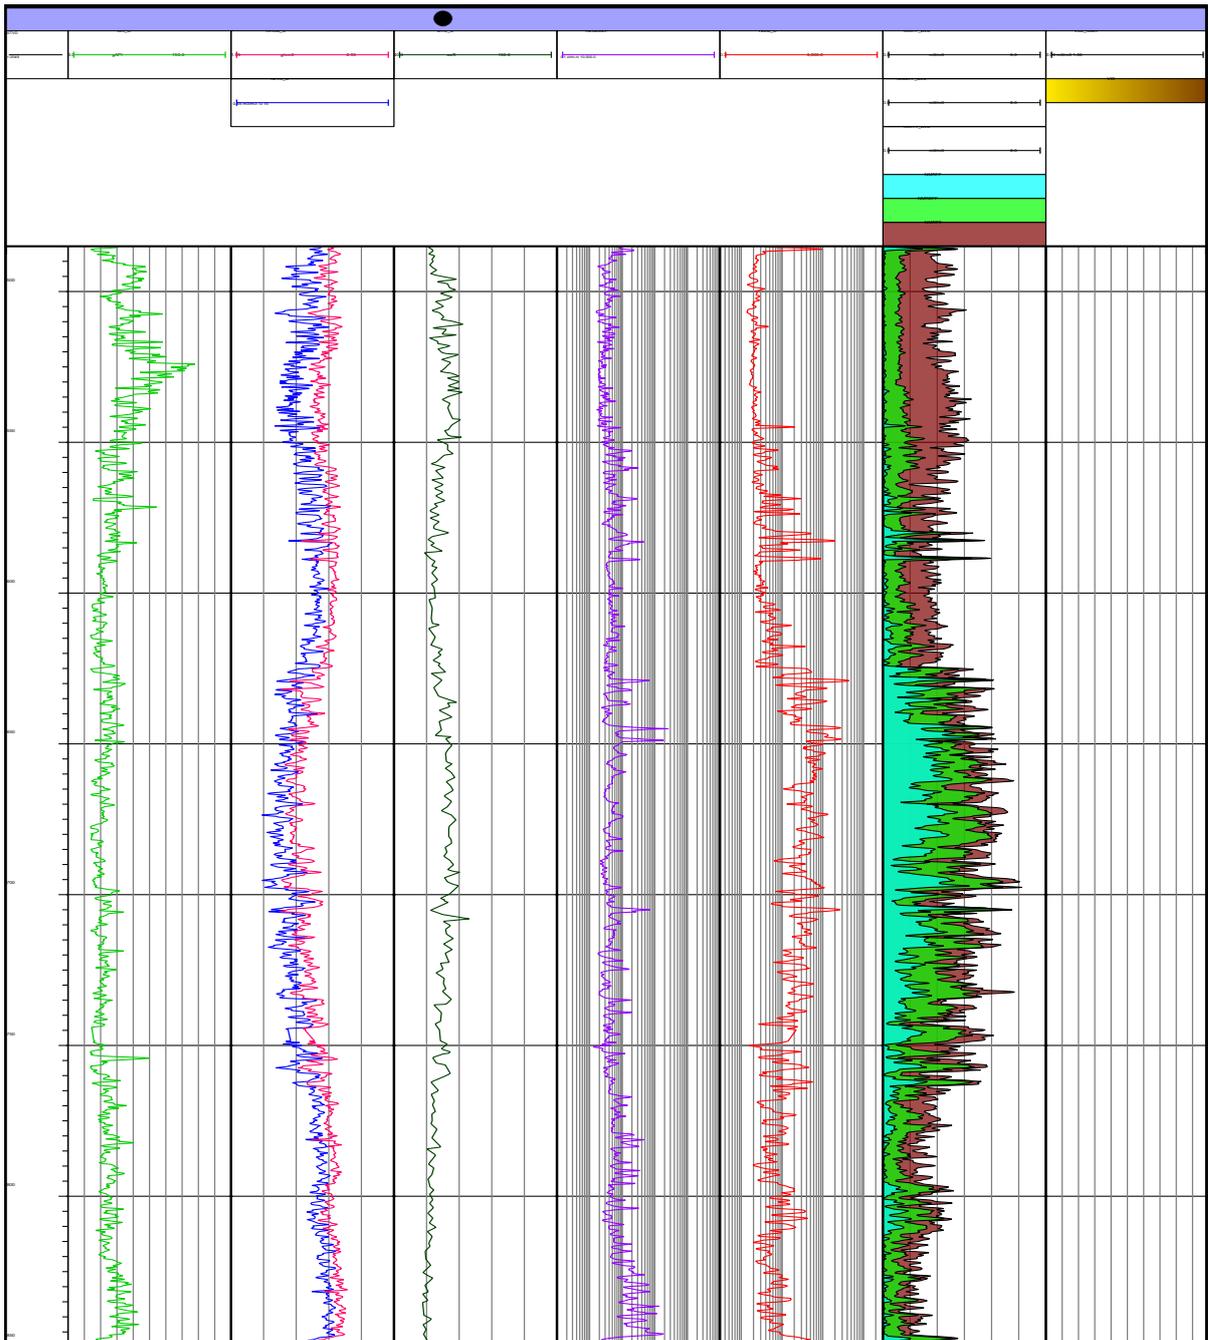


Figura 21. Perfis geofísicos no poço 3. (3-BRSA-1032-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

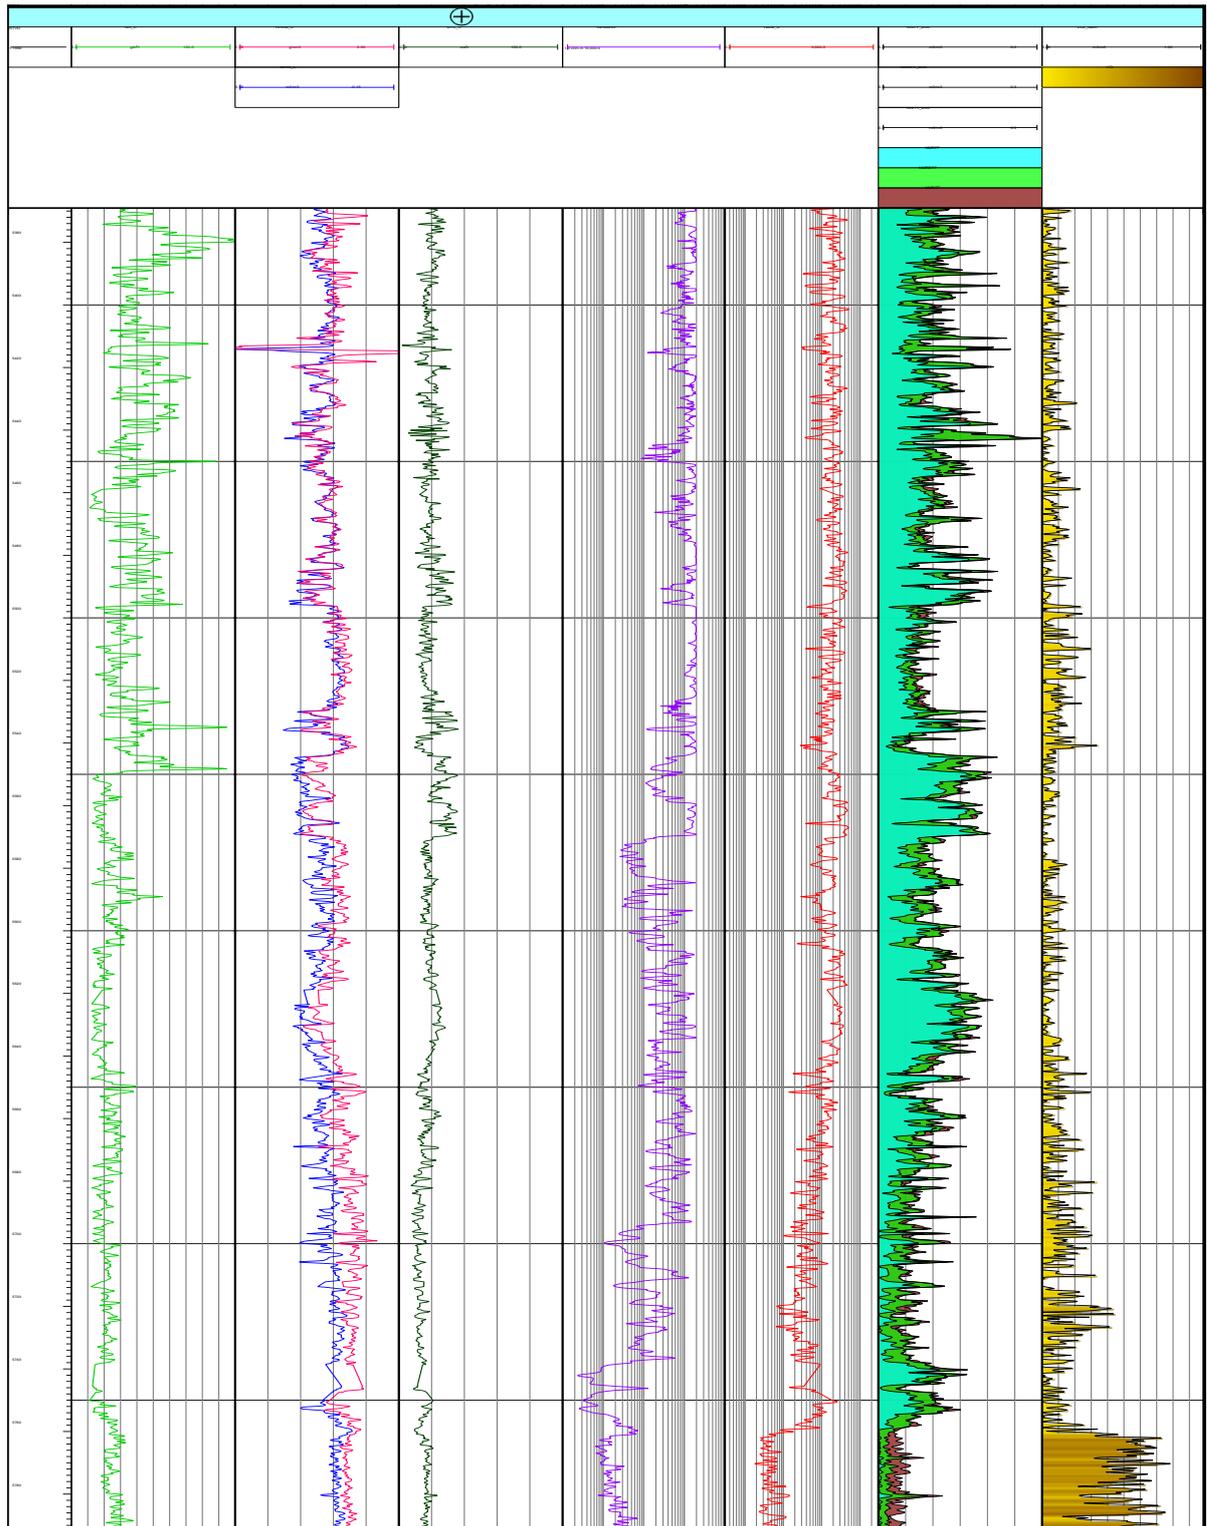


Figura 22. Perfis geofísicos no poço 4 (3-BRSA-1132-RJS): Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

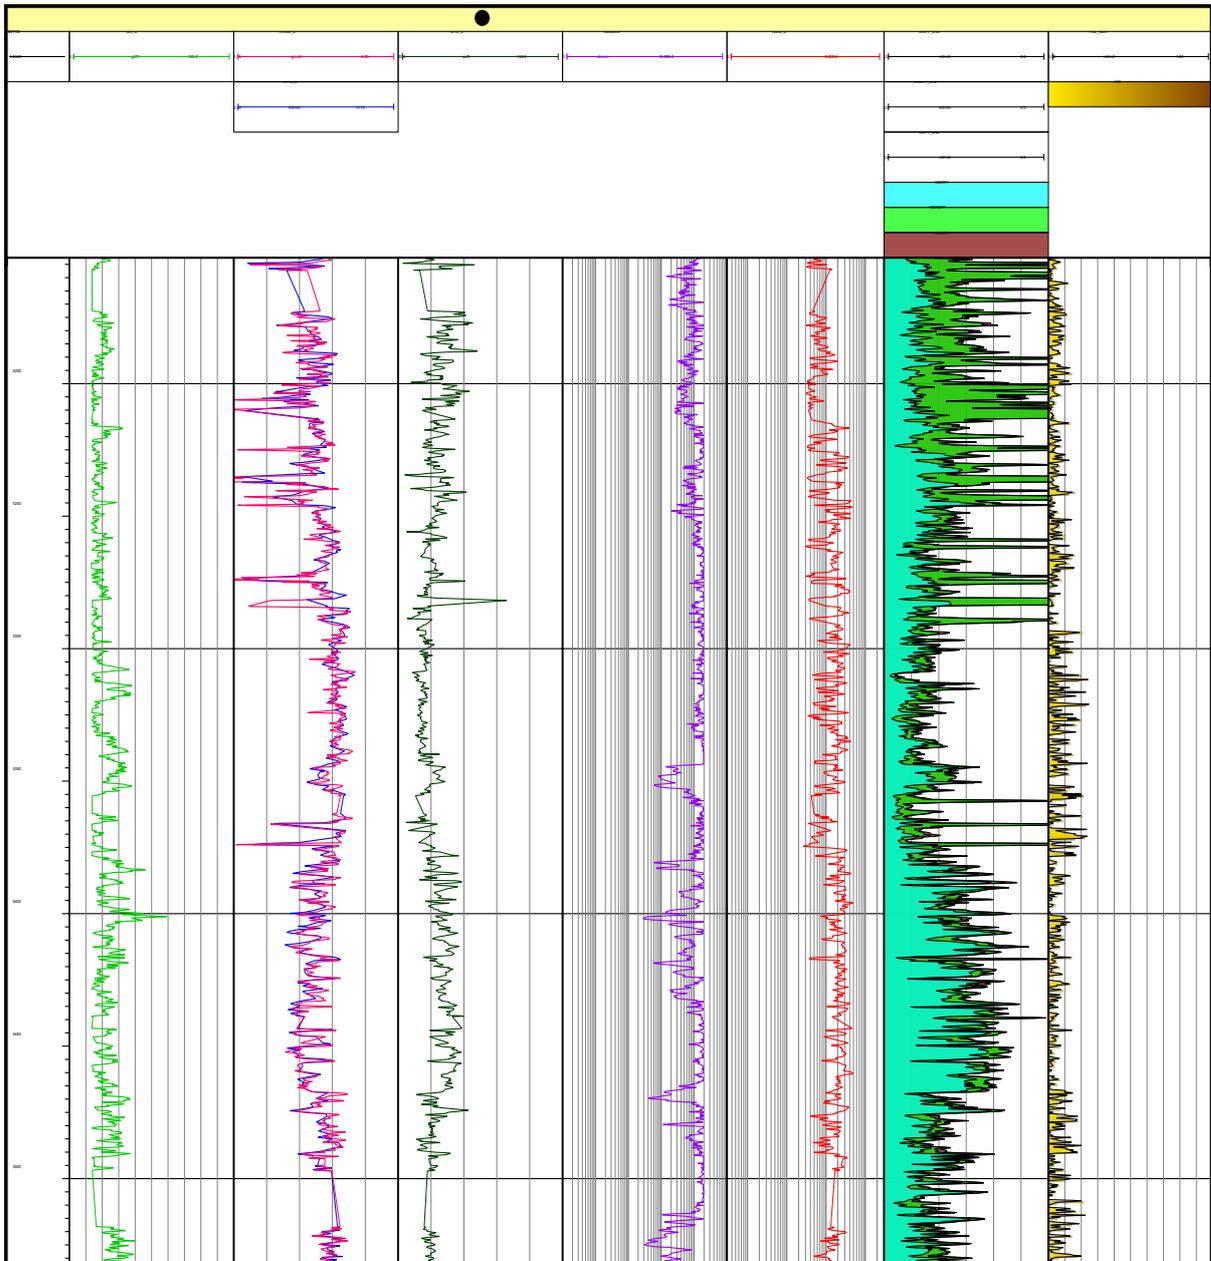


Figura 23. Perfis geofísicos no poço 5 (3-BRSA-1172-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

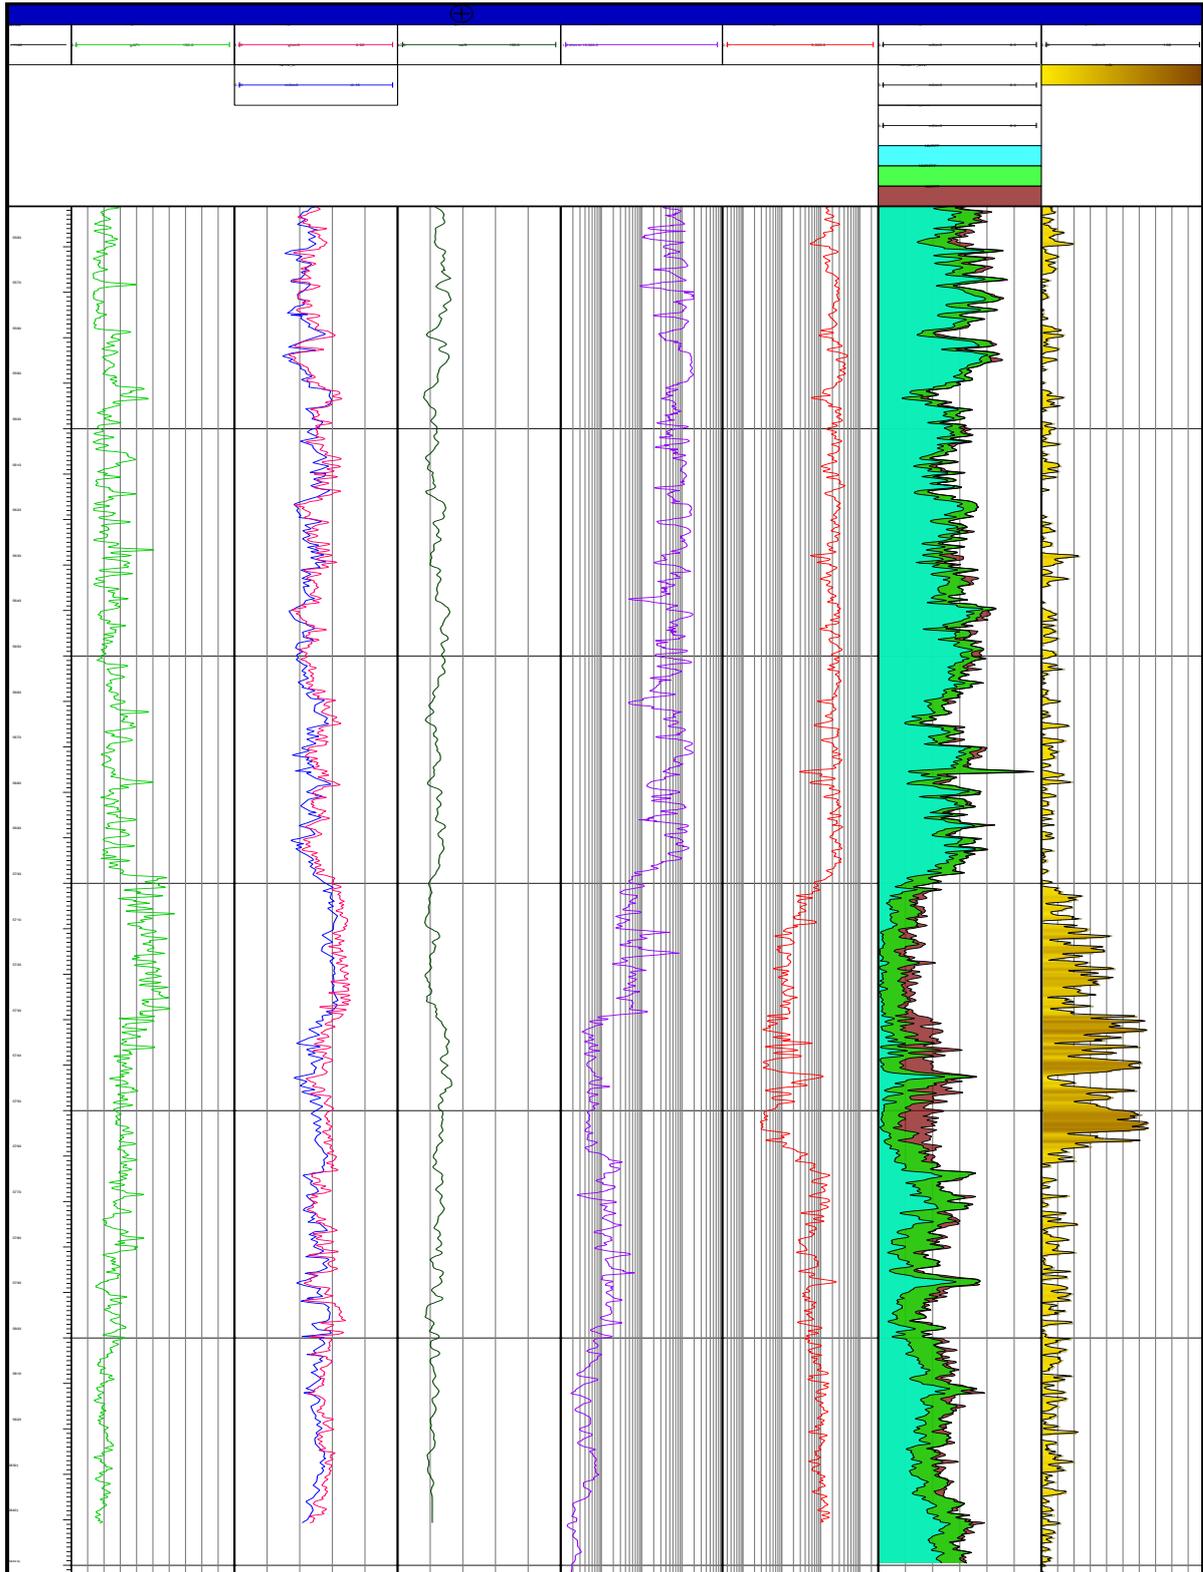


Figura 24. Perfis geofísicos no poço 6 (4-BRSA-1126-RJS). Raios gama (GR), Densidade (RHOB), nêutron (NPHI), sônico (DTC), resistividade (RT), média logarítmica do tempo 2 (T2LM), Ressonância Magnética Nuclear (RNM), volume dos grãos tamanhos tipo argila (Vclay).

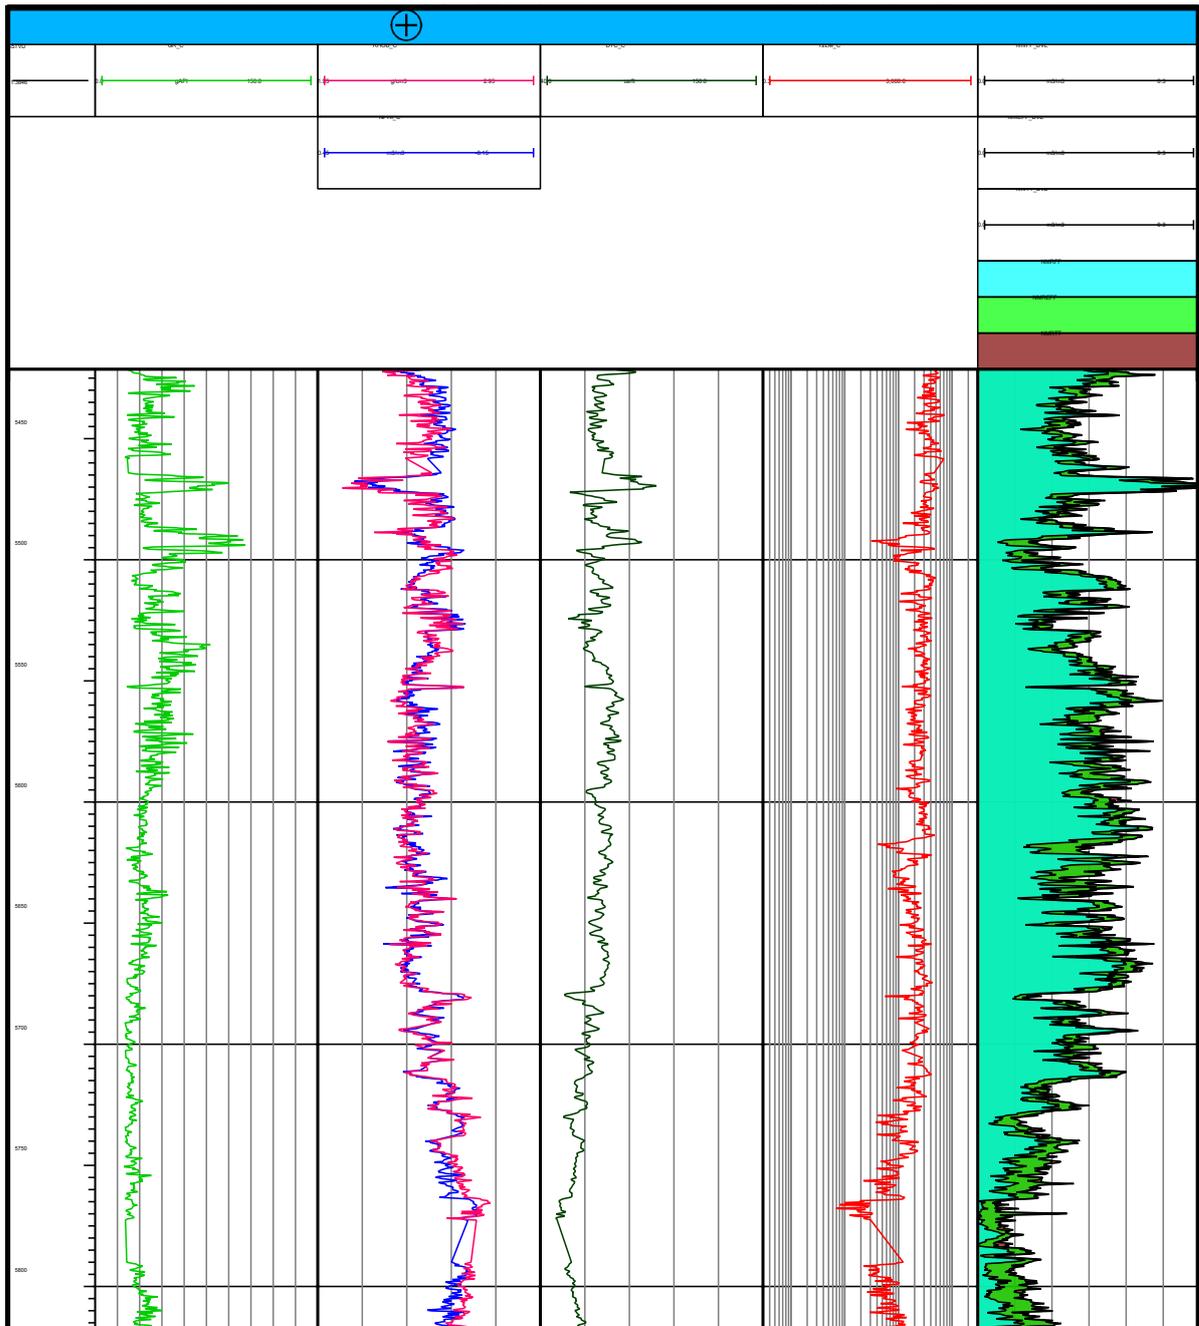


Figura 25. Perfis geofísicos no poço 7 (9-BRSA-1212-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); e Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF).

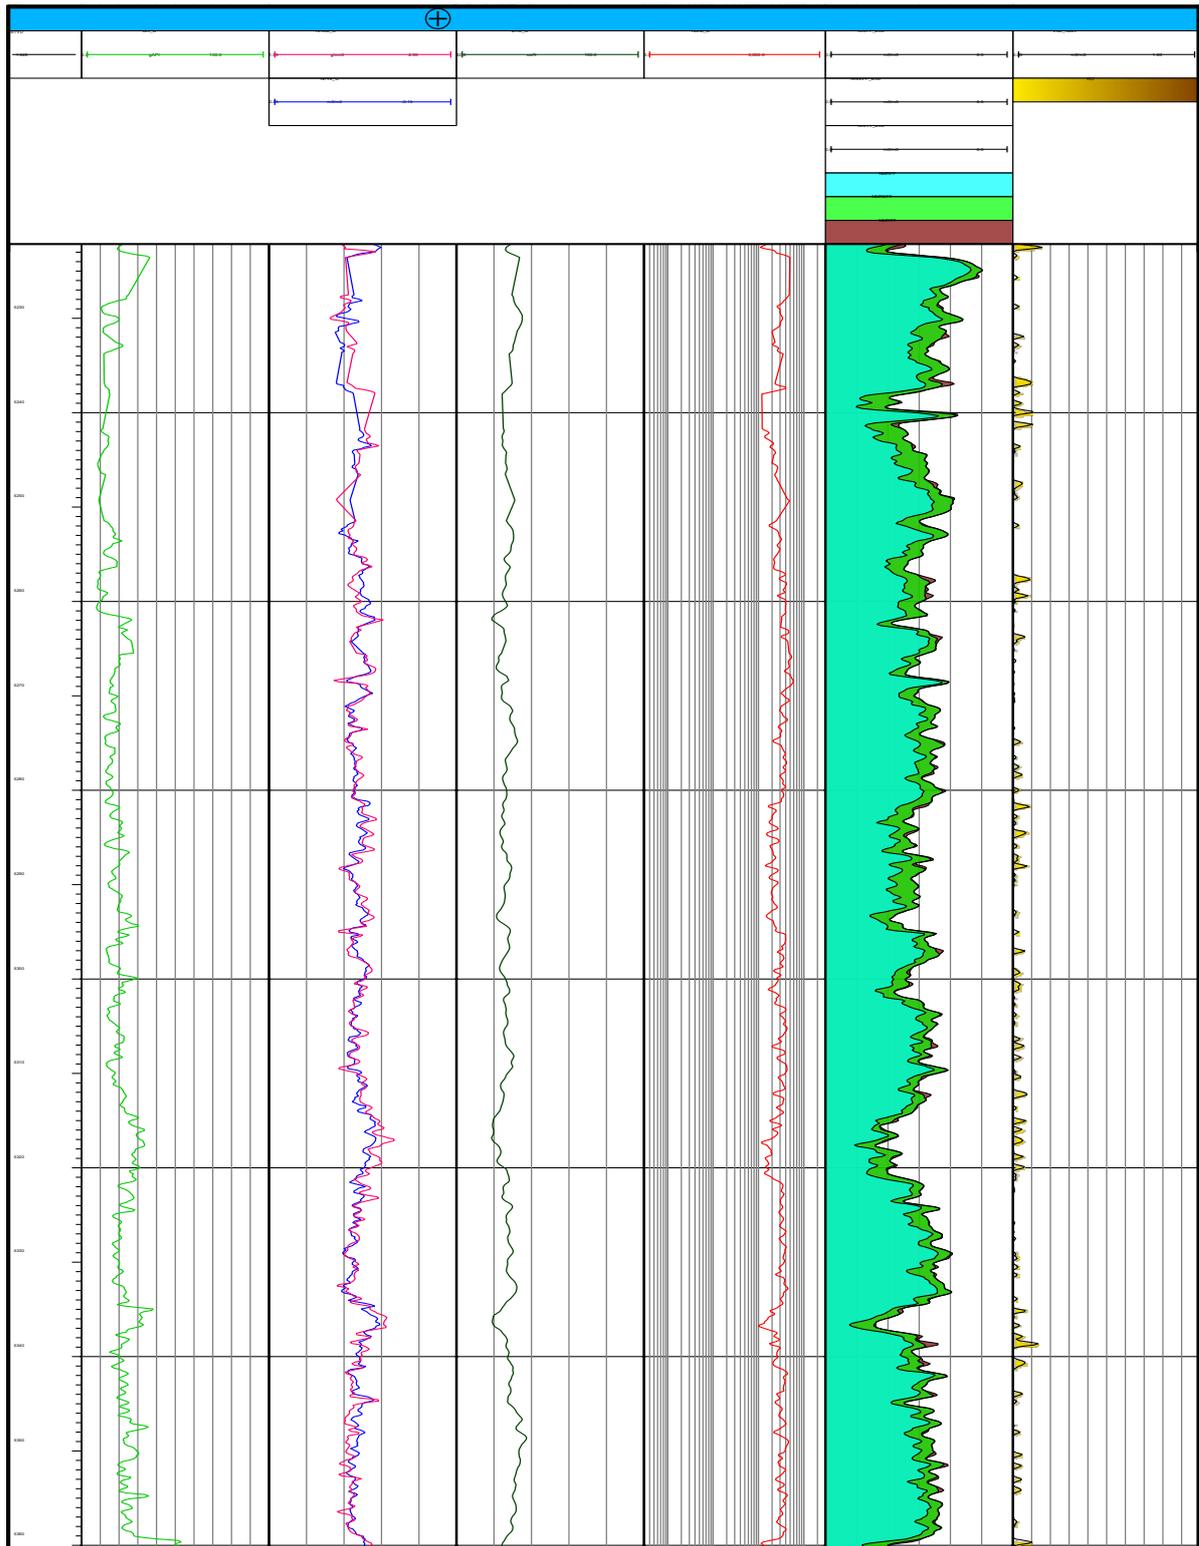


Figura 26. Perfis geofísicos no poço 8 (9-BRSA-1284-RJS). Raios Gama (GR), Densidade (RHOB); Nêutron (NPHI), Sônico (DTC); Resistividade profunda (RT); Média Logarítmica do Tempo 2 (T2LM); Resposta petrofísica da Ressonância Magnética Nuclear (RNM): porosidade total (NMRTT), porosidade efetiva (NMREFF) e fluidos livres (NMRFF); e Volume dos grãos tamanhos tipo argila (Vclay).

6.1.2. Modelagem petrofísica

Como resultado serão apresentados modelos petrofísicos de porosidade, permeabilidade e saturações de água-óleo. O cálculo do VShale foi realizado usando 2 metodologias, considerando as curvas de Raios Gama (GR) e considerando os perfis de Densidade (RHOB) e Neutrão (NPHI). Os valores de Vshale são calibrados com valores do perfil de VClay, o qual mostra a porcentagem de grãos tamanho argila de uma rocha em zonas que apresentam conteúdos normais de materiais radioativos (urânio, tório e potássio).

As metodologias aplicadas para a estimativa da porosidade total apresentaram valores diferentes entre si. Na determinação do modelo de porosidade efetiva desde esses resultados se tiveram também algumas discrepâncias no momento da calibração com os dados petrofísicos de laboratório. Realçando que, os modelos desde as metodologias do perfil de Densidade (RHOB) e a resposta da porosidade total (NMRTT) da Ressonância Magnética Nuclear (NMR) apresentaram as melhores calibrações. Porém, foi melhor a calibração com este último modelo. Desta maneira, as porosidades totais e efetiva por NMR foram utilizadas neste trabalho (Figura 27).

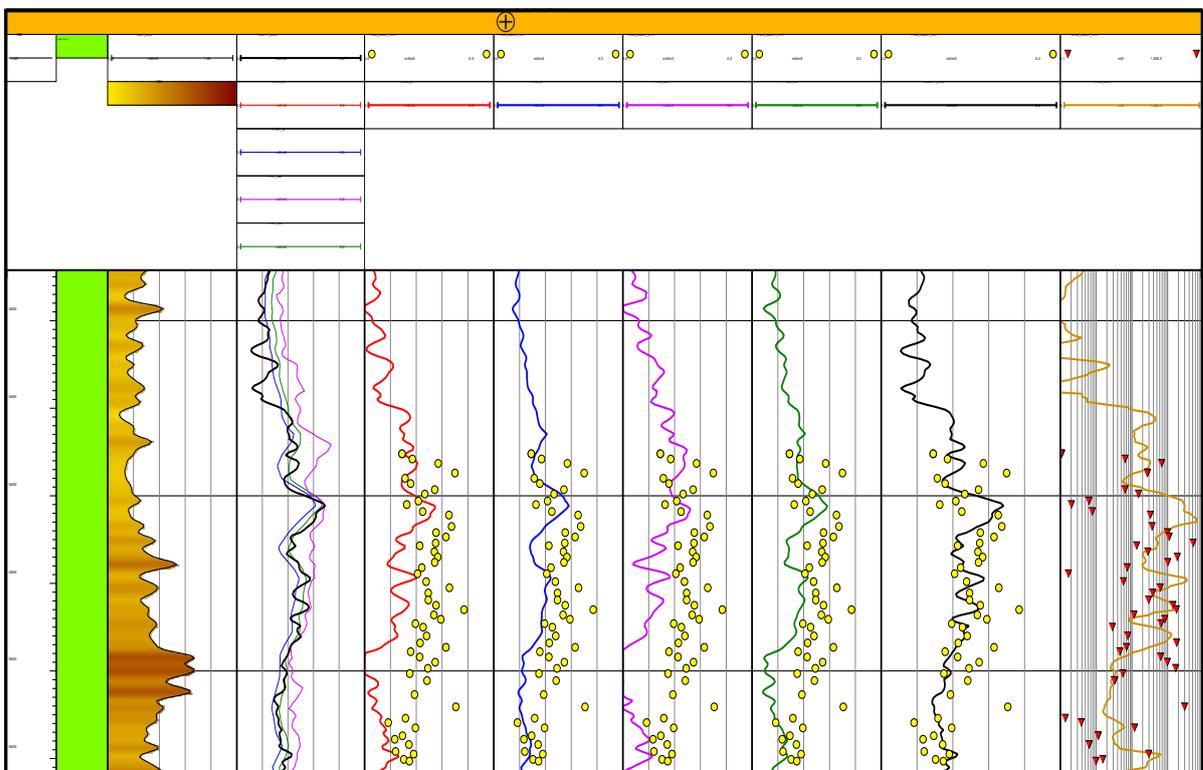


Figura 27. Modelos de porosidade total (PHIT) e modelos de porosidade efetiva (PHIE) calibrados com dados de laboratório no poço 2 (3-BRSA-891A-RJS). Os pontos amarelos e triângulos vermelhos representam os dados de laboratório de petrofísica efetiva e permeabilidade horizontal no testemunho.

Os resultados dos modelos de saturação de água e hidrocarbonetos obtidos através de 5 metodologias mostram diferentes valores de saturação de água. Diferentes saturações de óleo foram obtidas considerando que os reservatórios estão saturados apenas com água e óleo. Portanto, a soma de ambas as saturações é 1 assumindo-se como 100% de seus fluidos. Os valores obtidos de saturação de água não se podem calibrar porque não se tem dados laboratoriais que corroborem os dados (Figuras 28 a 31).

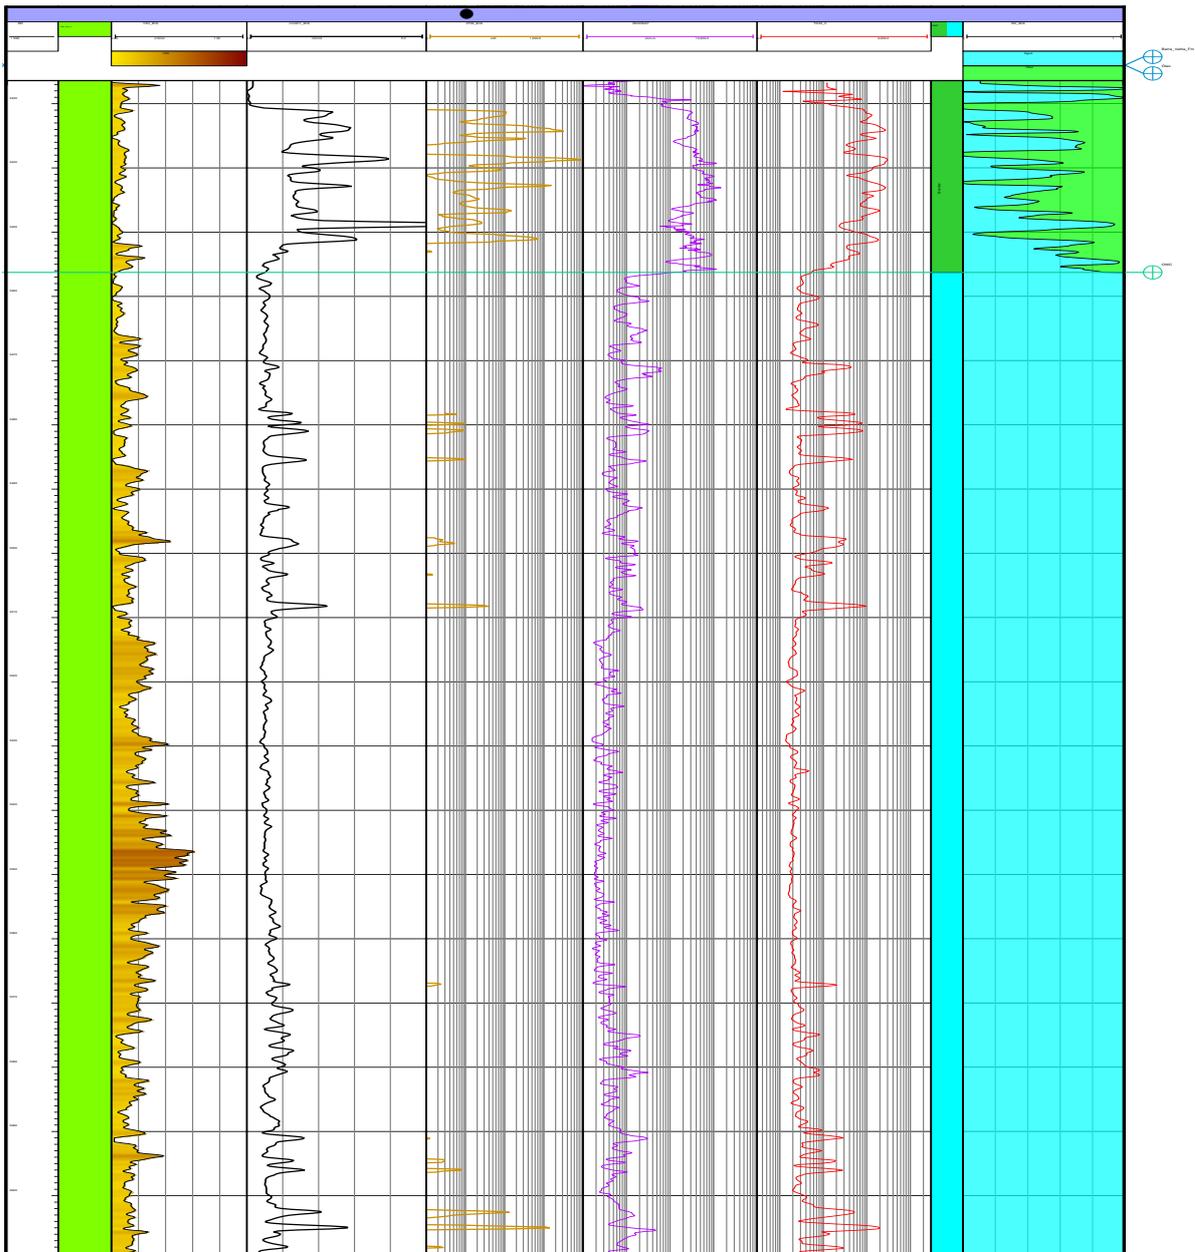


Figura 28. Modelos petrofísicos no poço 3 (3-BRSA-1032-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.

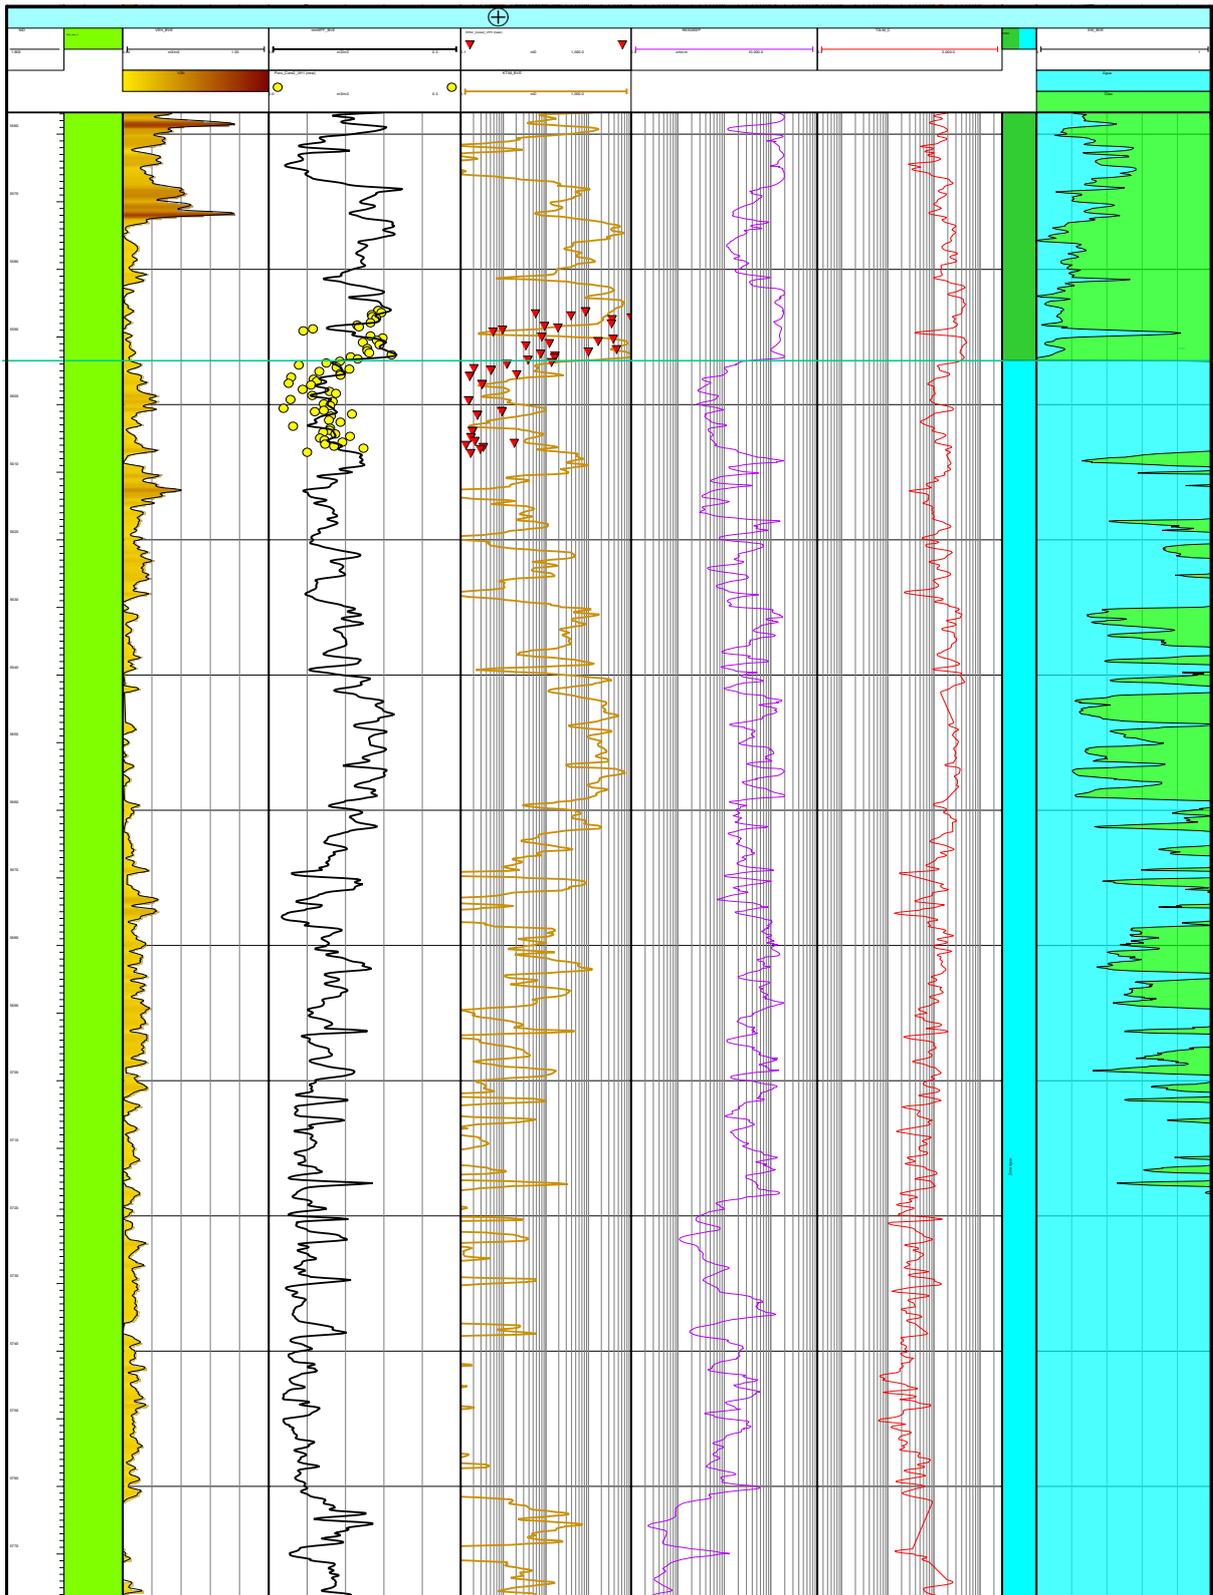


Figura 29. Modelos petrofísicos no poço 4 (3-BRSA-1132-RJS). Modelo de argilas, modelo de porosidade efetiva além de dados petrofísicos de porosidade efetiva (pontos amarelos), modelo de permeabilidade horizontal (KTIM) e dados petrofísicos de permeabilidade horizontal (triângulos vermelhos), modelo de saturação de água e óleo a partir do OWC.

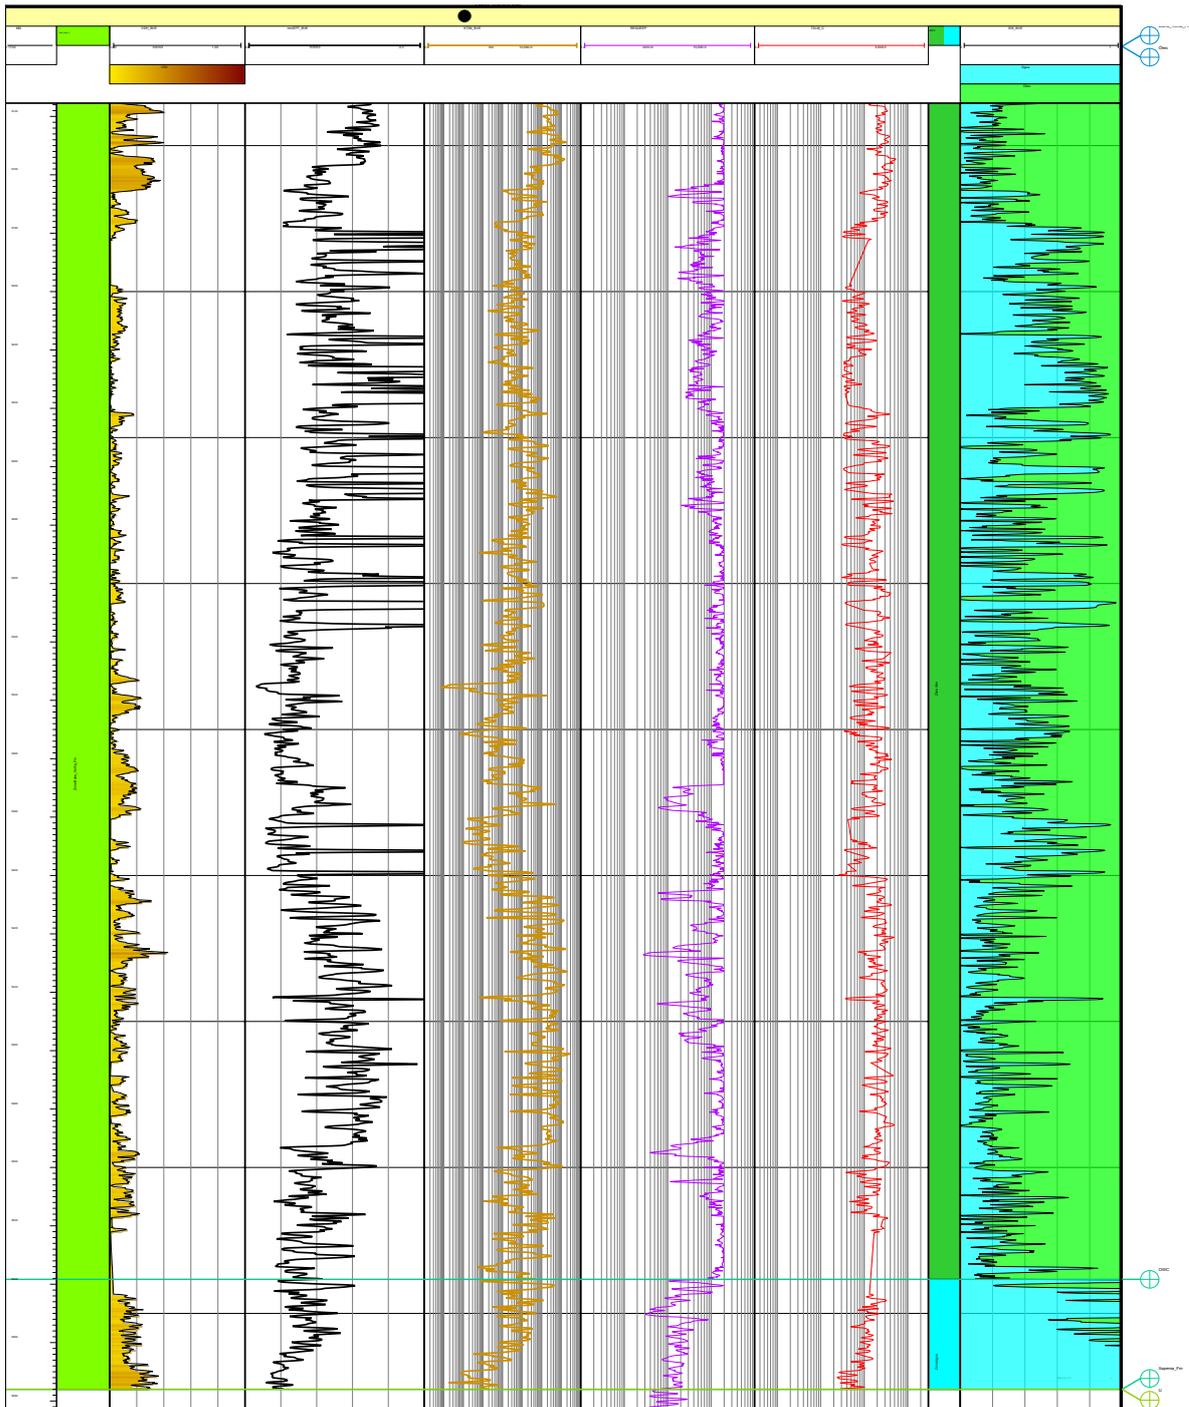


Figura 30. Modelos petrofísicos no poço 5 (3-BRSA-1172-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.

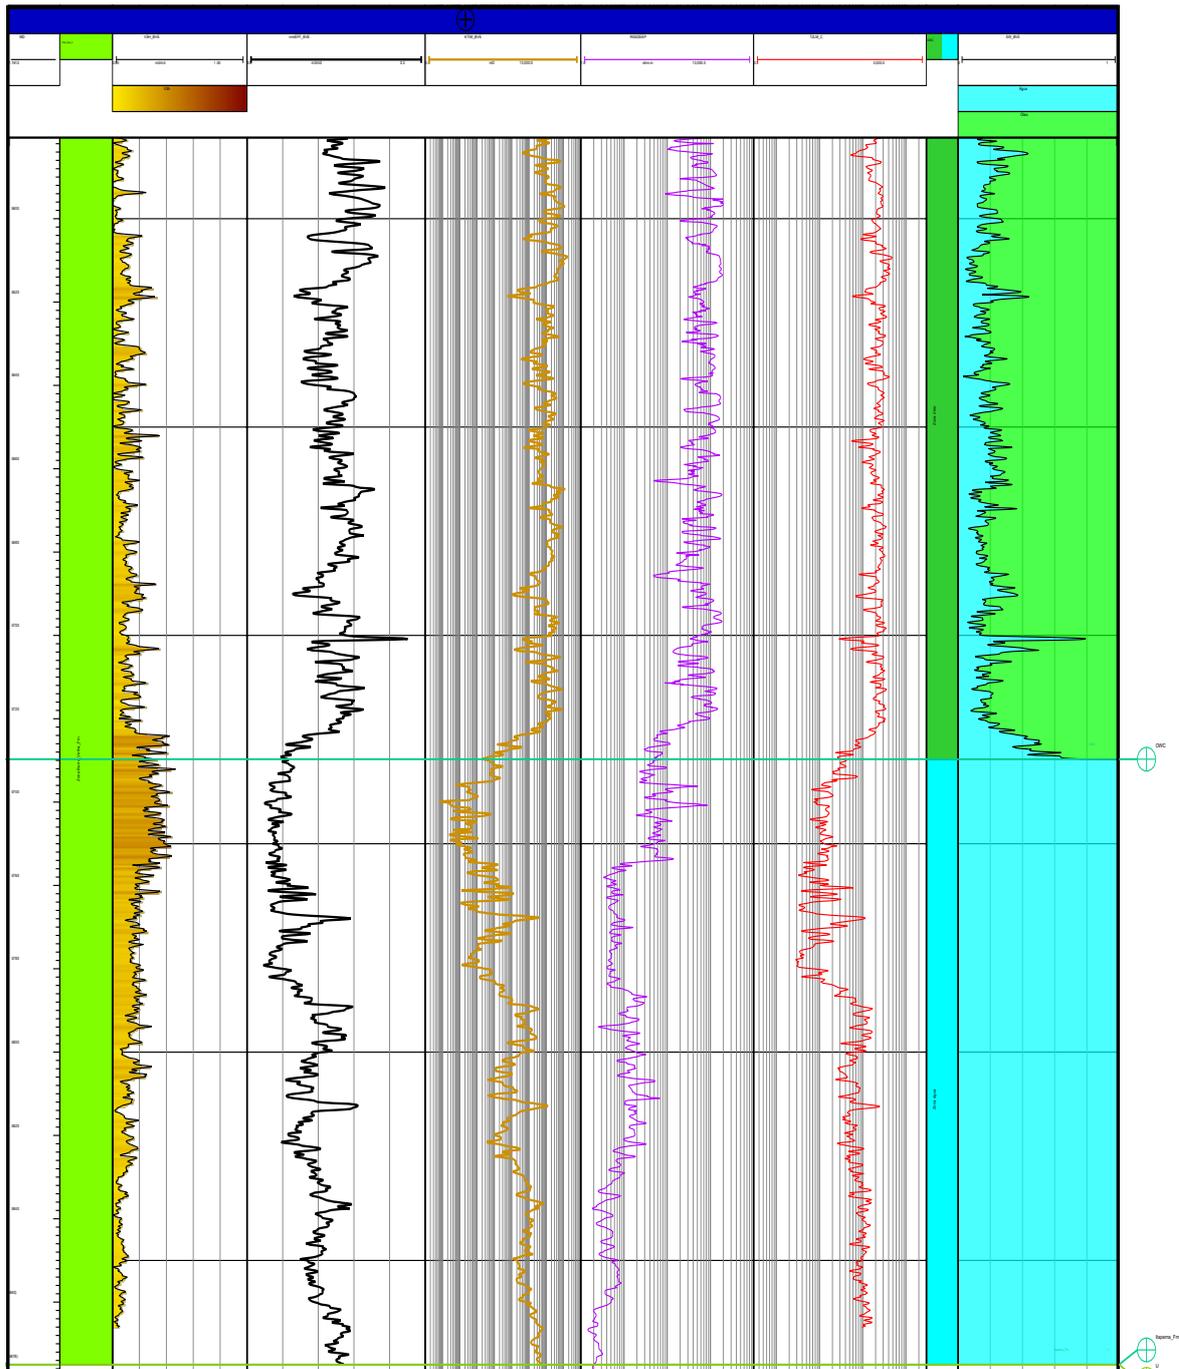


Figura 31. Modelos petrofísicos no poço 6 (4-BRSA-1226-RJS). Modelo de argilas, modelo de porosidade, modelo de permeabilidade horizontal (KTIM), modelo de saturação de água e óleo a partir do OWC.

6.1.3. Geração de eletrofácies e petrofácies através de algoritmos de aprendizagem de máquina

a. Eletrofácies obtidas por SVM

Foi realizada uma análise das lâminas delgadas para classificar as diferentes litofácies na área de interesse de acordo com a classificação de Gomes *et al* 2020, essa classificação foi feita para as lâminas obtidas nos poços 3-BRSA-891^a -RJS, 9 -BRSA-1212-RJS e 9-BRSA-1284-RJS, essas lâminas delgadas de rochas carbonáticas geralmente apresentam diferentes quantidades e tipos de porosidade primária, fechadas e reabertas por múltiplas fases diagenéticas. As litofácies mais representativas dos poços serão apresentadas a seguir (Tabelas 1 a 3).

Tabela 1. Classificação para cada uma das litofácies disponíveis no poço 3-BRSA-891A-RJS.

PROFUNDIDADE	LITOFACIE	DESCRIÇÕES ADICIONAIS
5436	Muddy Spherulitestone	70% Spherulites e 30% Mud
5437	<i>Mudstone</i>	
5439	Laminite	
5441	Spherulitic <i>Mudstone</i>	50% Spherulites e 50% Mud
5448	<i>Grainstone</i>	
5452	Shrubstone	
5522	<i>Packstone</i>	
5544	Shrubby spherulitestone with mud	35% Spherulite, 15% Shrub e 50% Mud
5558	Spherulitestone	

Inicialmente a classificação das litofácies foi realizada nas lâminas delgadas disponíveis conforme o agrupamento de litofácies de Gomes *et al.*, 2020 e o esquema de Duham, 1962 (descrito na teoria), é importante ressaltar que algumas das lâminas apresentavam alguns sinais de dolomitização ou amostras de materiais ferrosos, como os seguintes exemplos (Figuras 32 a 35).

Tabela 2. Classificação as litofácies disponíveis no poço 9-BRSA-1212-RJS.

PROFUNDIDADE	LITOFACIE	DESCRIÇÕES ADICIONAIS
5349.5	<i>Grainstone</i>	
5357.5	Laminite	
5373.5	Spherulitestone	
5377.5	Muddy Spherulitestone	70% Spherulites 30% Mud
5574.5	Spherulitic <i>Mudstone</i>	50% Spherulites 50% Mud

Tabela 3. Classificação para cada uma das litofácies disponíveis no poço 9-BRSA-1284-RJS.

PROFUNDIDADE	LITOFACIE	DESCRIÇÕES ADICIONAIS
5252.0	<i>Schrubstone</i>	
5507.8	<i>Mudstone</i>	

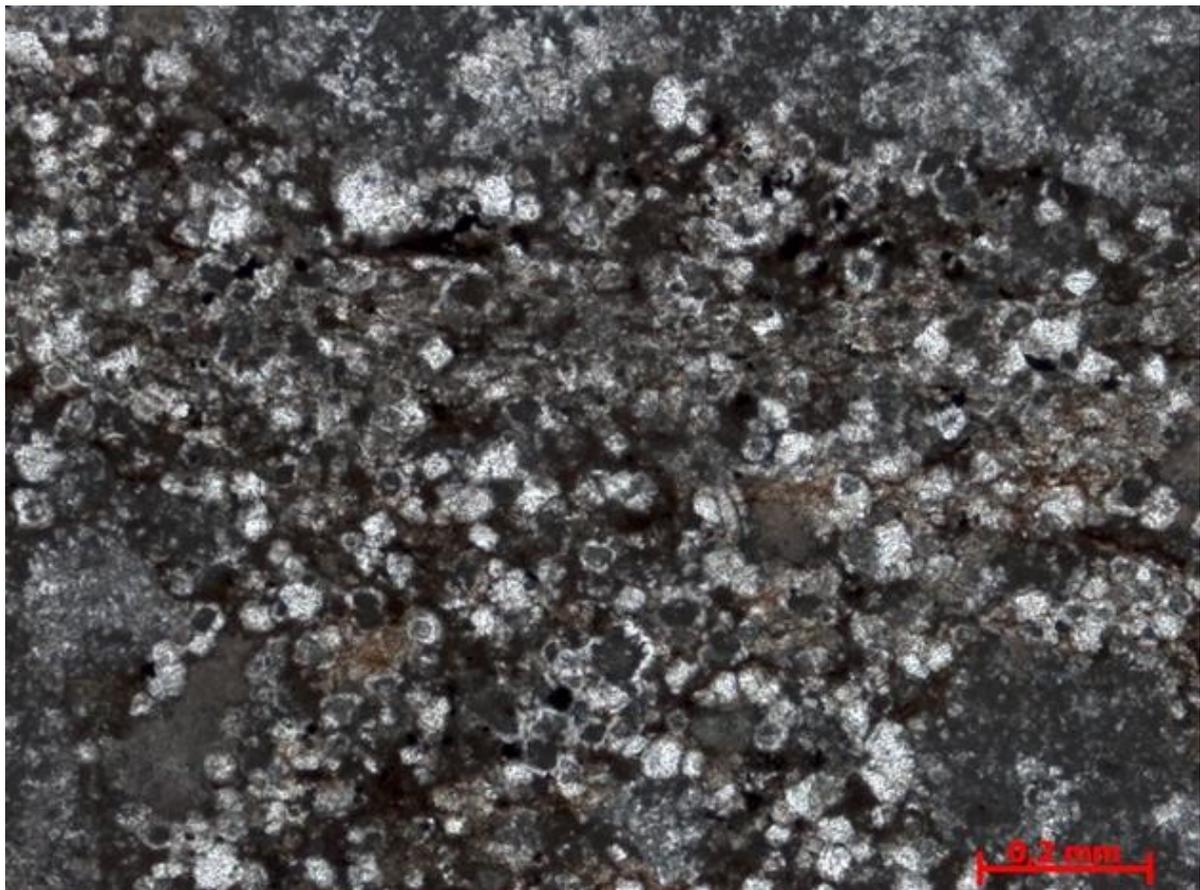
Figura 32. Lâmina delgada de *Grainstone* com alta presença de dolomita.



Figura 33. Lâmina delgada de Spherulitstone com pequenas amostras de Dolomita (círculos vermelhos).

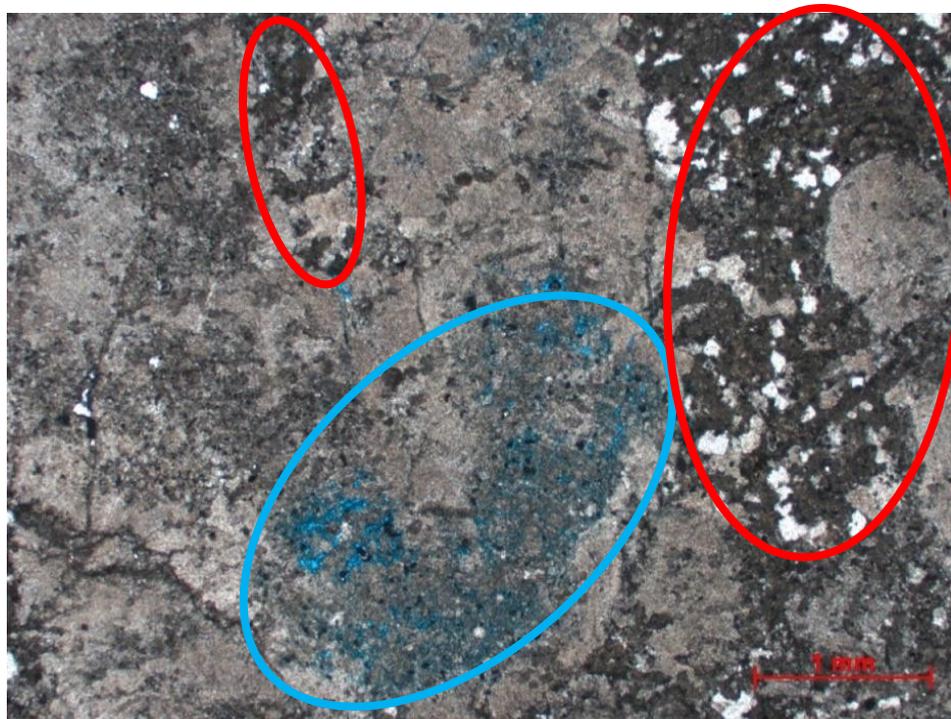


Figura 34. Lâmina delgada de *Schrubstone* com pequenas amostras de Dolomita. Onde pode-se observar espaços porosos (círculo azul) e esses espaços podem ser preenchidos por calcita que se transforma em dolomita devido a alterações diagenéticas (círculos vermelhos).

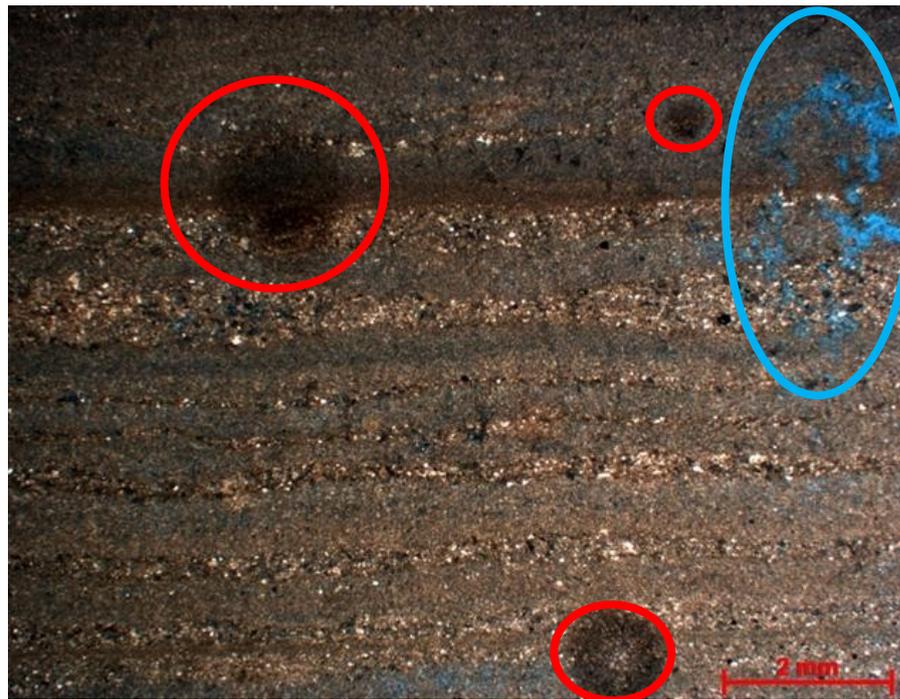


Figura 35. Lâmina delgada de Laminite com a presença de materiais ferrosos (círculos vermelhos) e presença de porosidade secundária (círculo azul).

Essas características são importantes de serem destacadas, dessa forma é possível entender que nem todas as lâminas apresentaram uma característica estruturada sem variações, portanto, a faixa de respostas dos perfis geofísicos em cada uma das Eletrofácies classificadas foi amplo.

O agrupamento das eletrofácies *Mudstone-Laminite*, *Spherulitestone*, *Schrubstone* e *Grainstone* (1,2,3 e 4 respectivamente) tornou-se ideal, pois quando foram observadas as profundidades em que havia lâminas do mesmo grupo de classificação, houve uma tendência de respostas nos perfis, que permitiu o seu agrupamento (GR, Vshale, RHOB, NPHI, DTC, T2LM).

A implementação de algoritmos de aprendizado de máquina é complexa, pois rochas carbonáticas tendem a ter respostas geofísicas bastante semelhantes, além de apresentar alta variabilidade devido a processos diagenéticos e alterações muito acentuadas. O pré-processamento dos dados foi feito com escala de variáveis (normalização de escala ou *MinMax Scaler*) por meio da Equação 27.

$$X_{Norm} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) * 100 \quad (\text{Equação 27})$$

Onde: X_{Norm} é o valor normalizado, X é o valor que se quer normalizar, X_{min} é o valor mínimo e X_{max} é o valor máximo.

Como resultado da implementação do *SVM* Radial no *software* RStudio foi obtida uma precisão ou exatidão de 0.818. Este valor de precisão foi afetado fortemente pela eletrofácies 1. Na Figura 36 é apresentada a matriz de confusão obtida para o *SVM* Radial, onde são cruzados o número de camadas implementadas em uma profundidade específica para cada eletrofácies: *Mudstone-Laminite* (1), *Spherulitestone* (2), *Shrubstone* (3) e *Grainstone* (4), mostrando ainda dados que apresentaram confusão quando são confrontados na matriz de confusão na Figura 37.

	1	2	3	4
1	785	17	2	69
2	4	74	0	0
3	0	0	188	3
4	2	1	2	267

Figura 36. Matriz de confusão do algoritmo de aprendizado de máquina supervisionado (*SVM* Radial).

O modelo radial foi implementado para prever as eletrofácies nos 8 poços (Figuras 40 e 42). Onde eletrofácies 1 é *Mudstone/Laminite* (marrom), eletrofácies 2 é *Spherulitestone* (amarelo claro), eletrofácies 3 é *Shrubstone* (verde) e eletrofácies 4 é *Grainstone* (azul) (Figura 38).

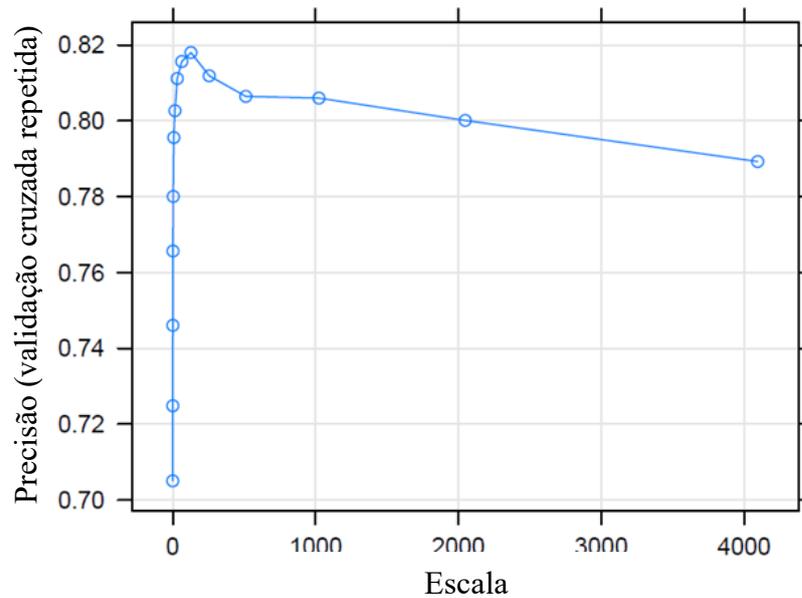


Figura 37. Gráfico de validação de precisão da metodologia SVM Radial.

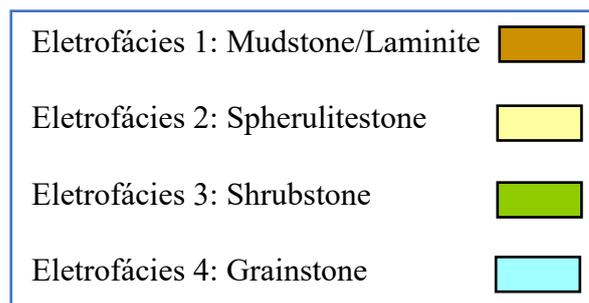


Figura 38. Classificação das cores de eletrofácies.

b. Petrofácies obtidas pelo K-means clustering.

Como resultado da implementação do algoritmo de aprendizagem de máquina não supervisionado *K-Means Clustering* para os 8 poços (Figuras 43 e 44), e foram obtidas as seguintes 3 petrofácies: Possível reservatório (amarelo), não reservatório (cinza) e reservatório (laranja, Figura 39). Na Figura 42 é apresentado o Cluster plot das petrofácies em RStudio

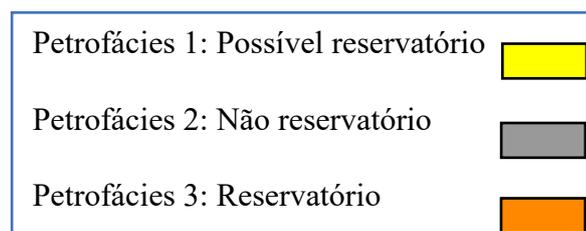


Figura 39. Classificação das cores de petrofácies.

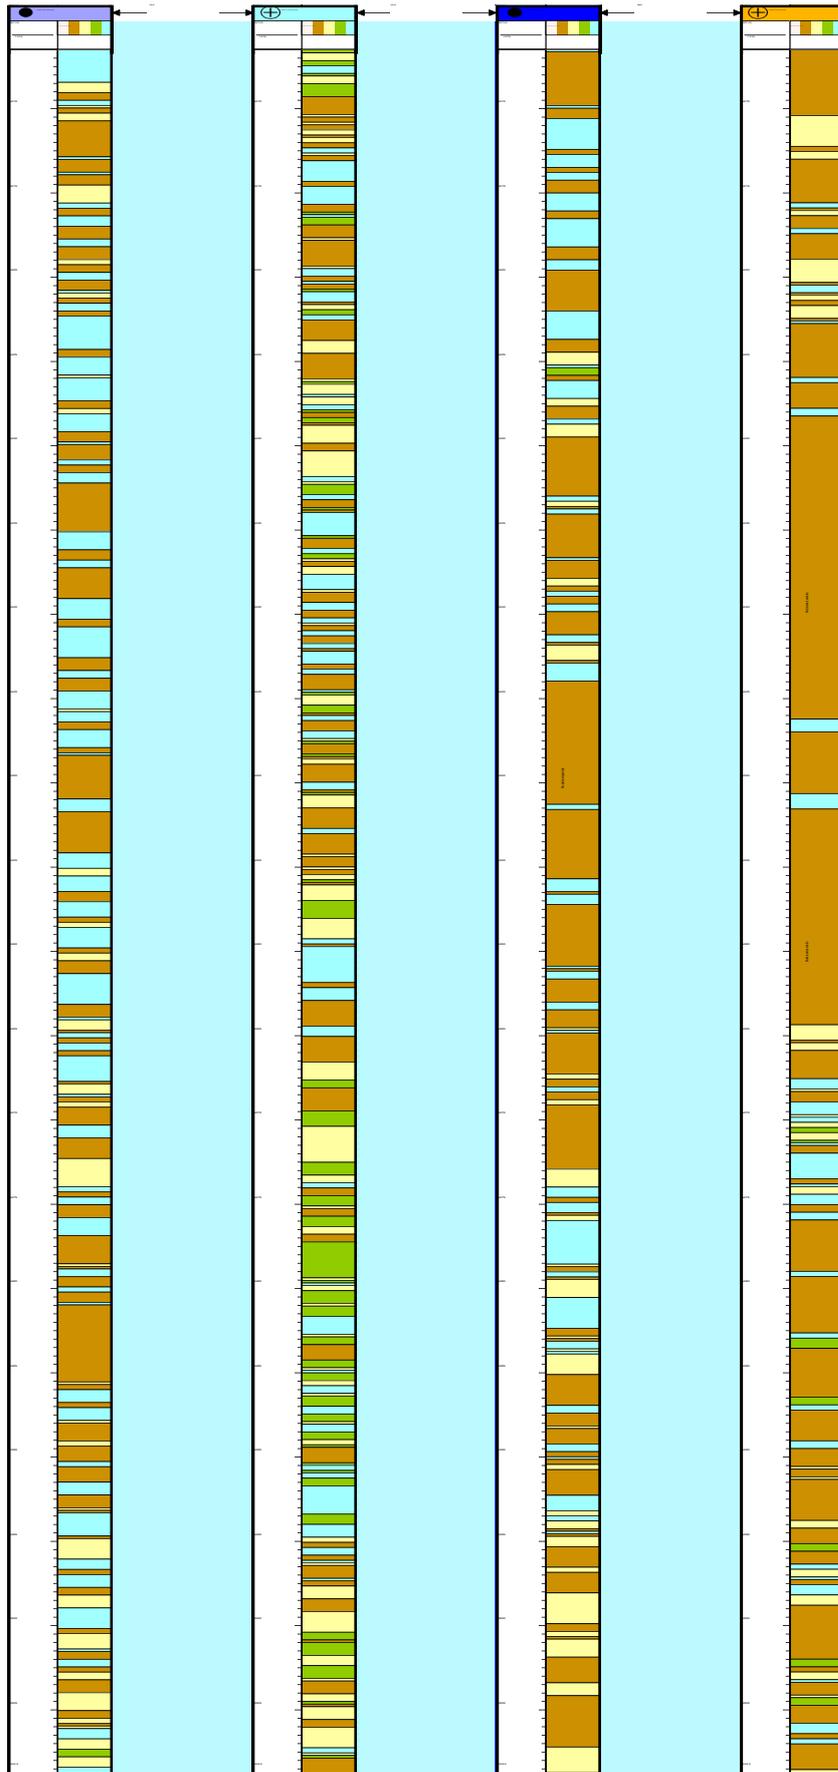


Figura 40. Modelo de eletrofácies litológicas desde o SVM Radial para os poços 1, 2, 3 e 4.

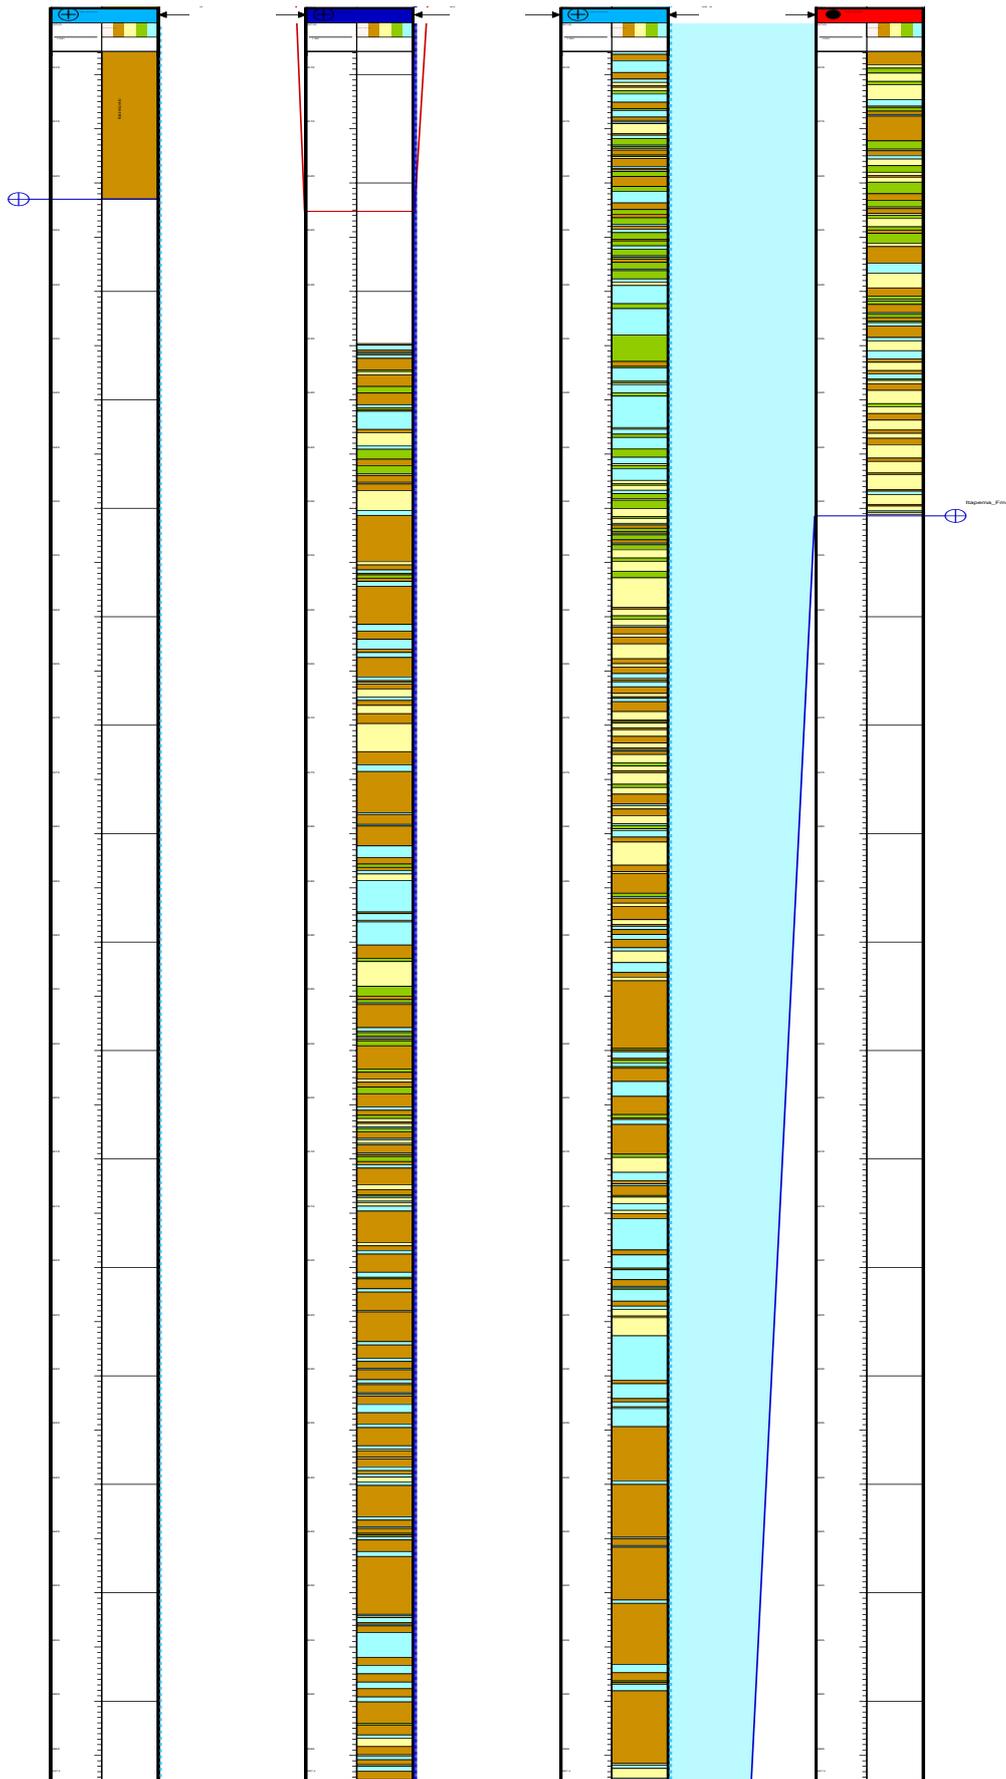


Figura 41. Modelo de eletrofácies litológicas desde o SVM Radial para os poços 5, 6, 7 e 8.

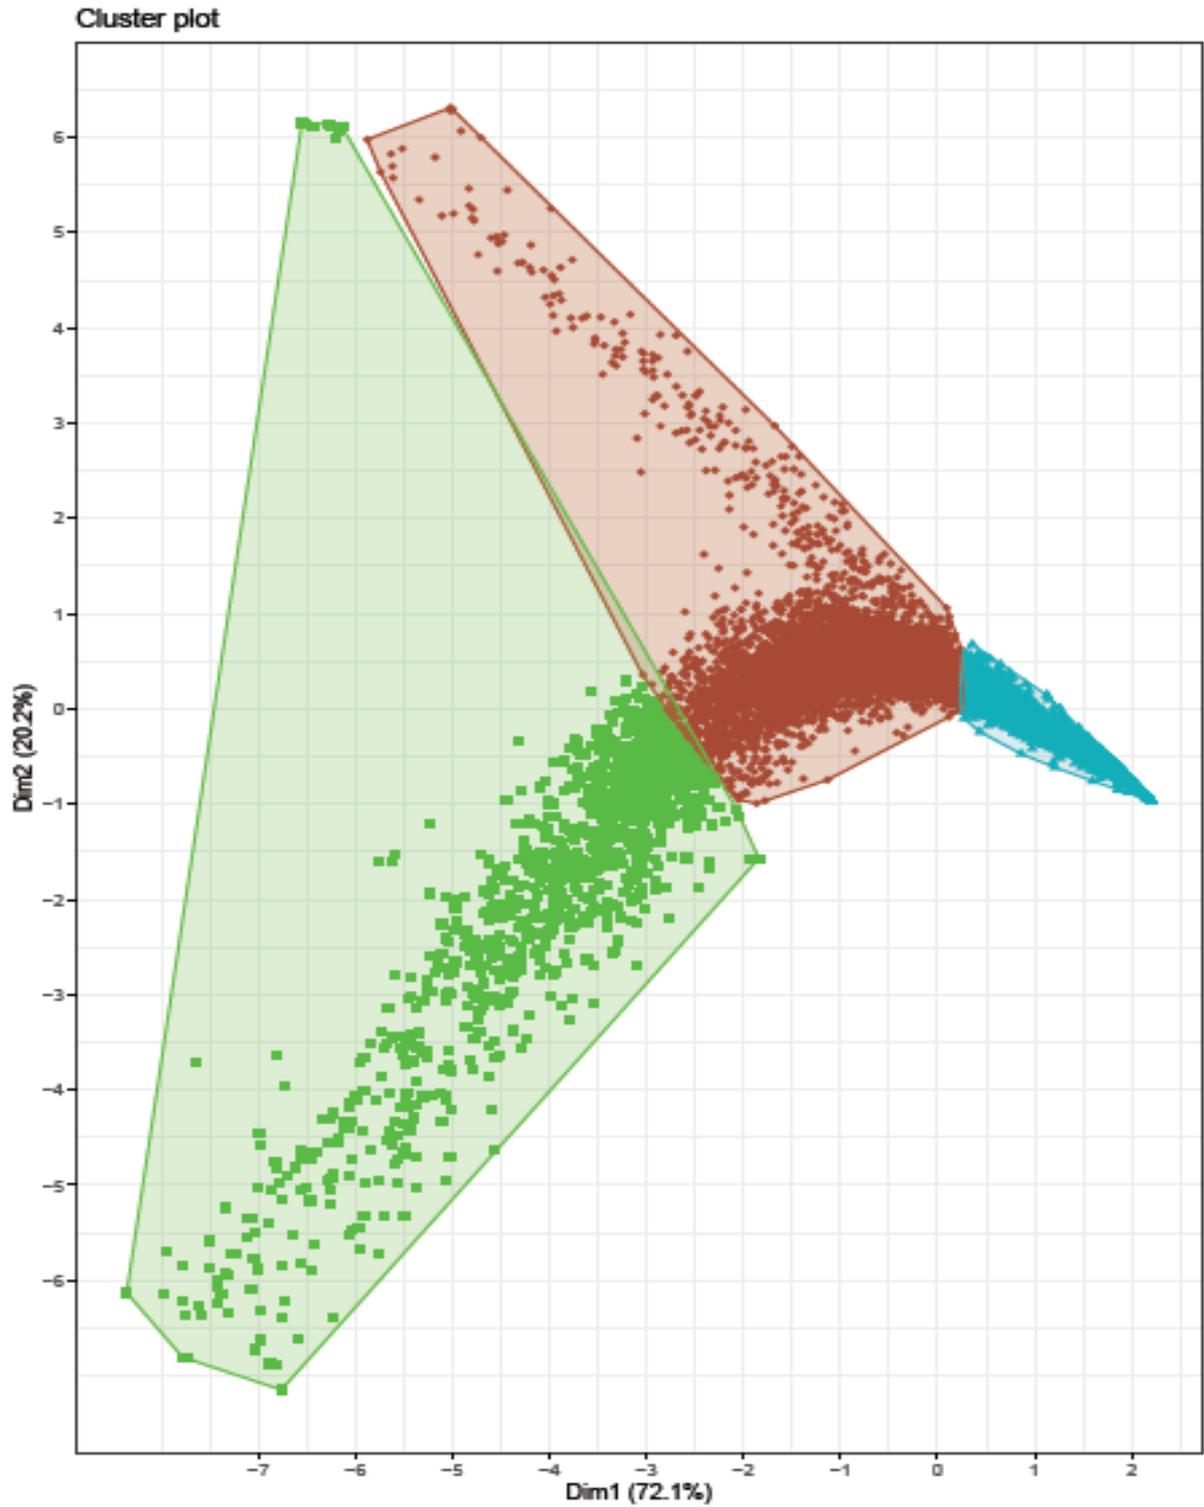


Figura 42. Cluster plot das petrofácies em RStudio. As cores neste gráfico foram automáticas e representam o verde é a petrofácies não reservatório, marrom é a petrofácies possível reservatório e azul é a petrofácies Reservatório.

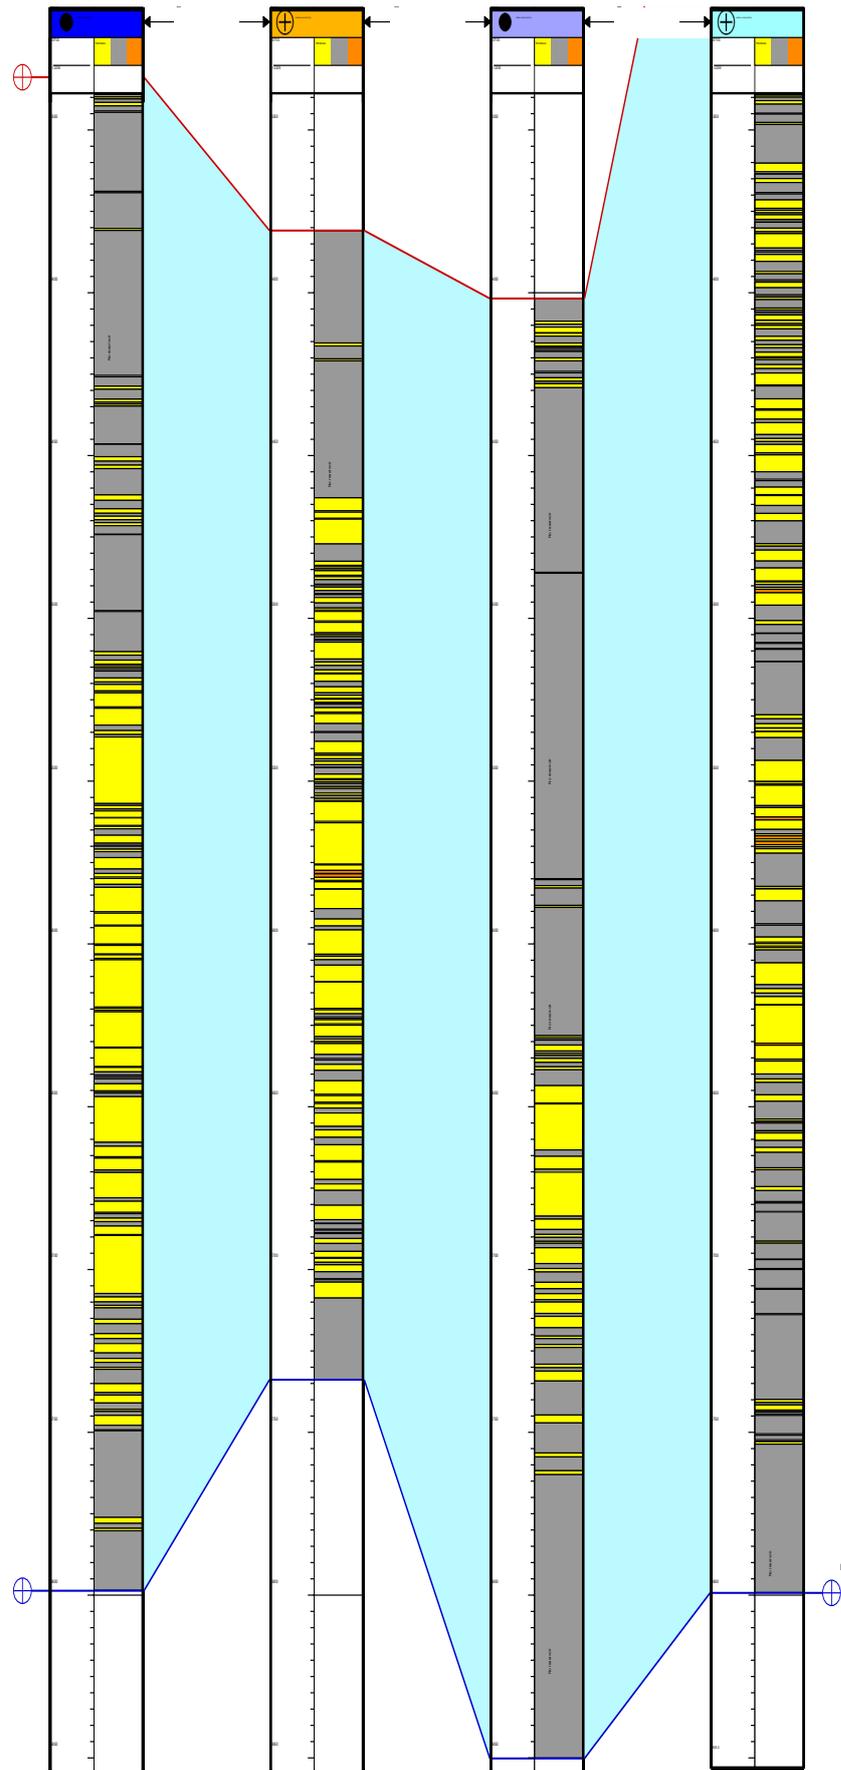


Figura 43. Modelo de petrofácies previstas por K-Means Clustering para os poços 1, 2, 3 e 4.

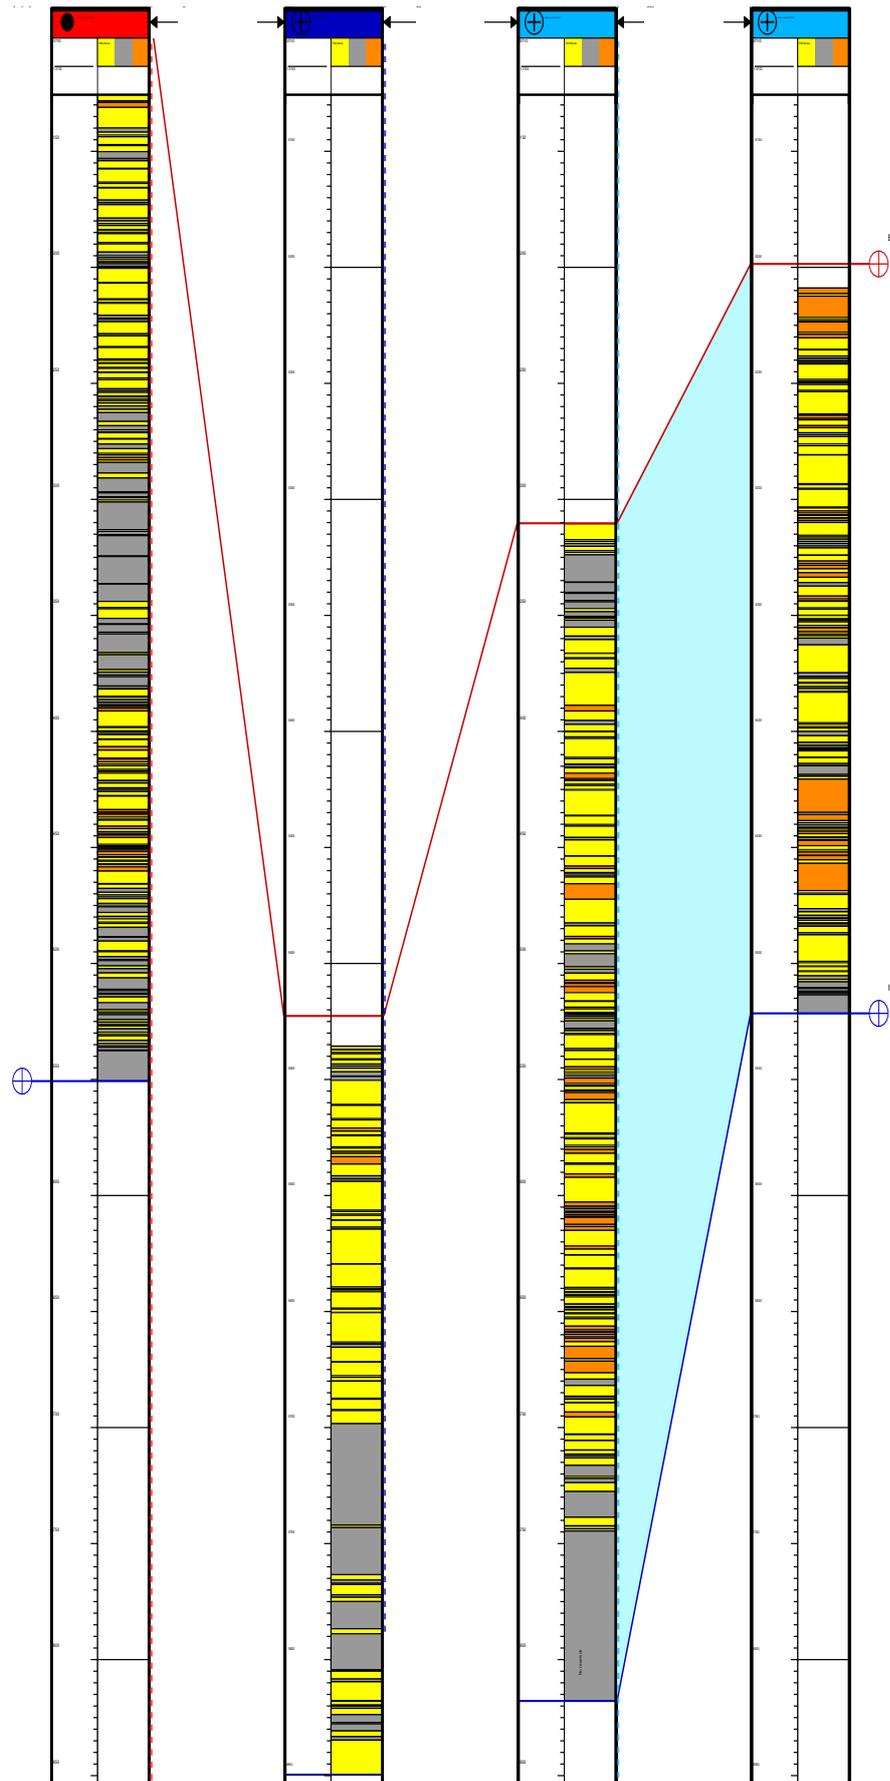


Figura 44. Modelo de petrofácies previstas por K-Means Clustering para os poços 5, 6, 7 e 8.

6.1.4. Geração de unidades de fluxo

Quatro (4) unidades de fluxo foram determinadas por meio do gráfico estratificado modificado de Lorenz (Figura 45) e o gráfico de discretização de unidades de fluxo horizontais de Penna e Lupinacci (2021) (Figura 46).

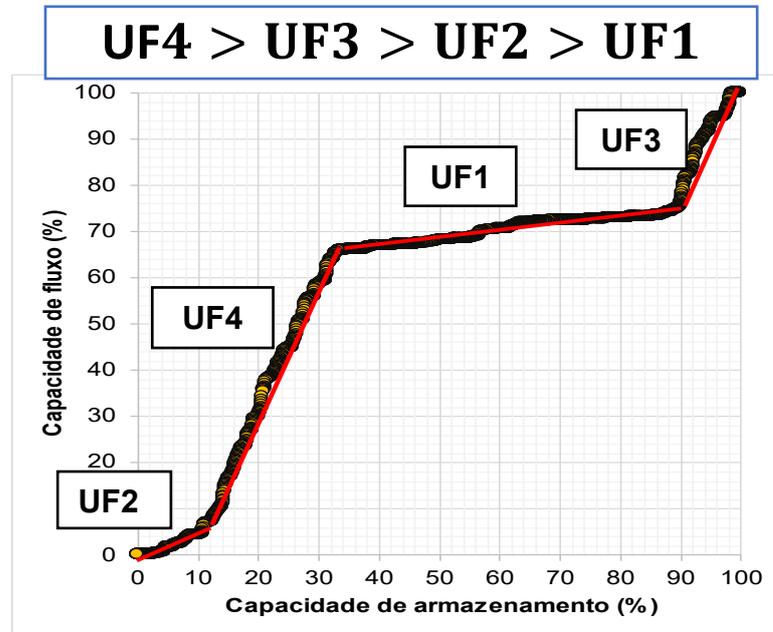


Figura 45. Gráfico estratificado modificado de Lorenz.

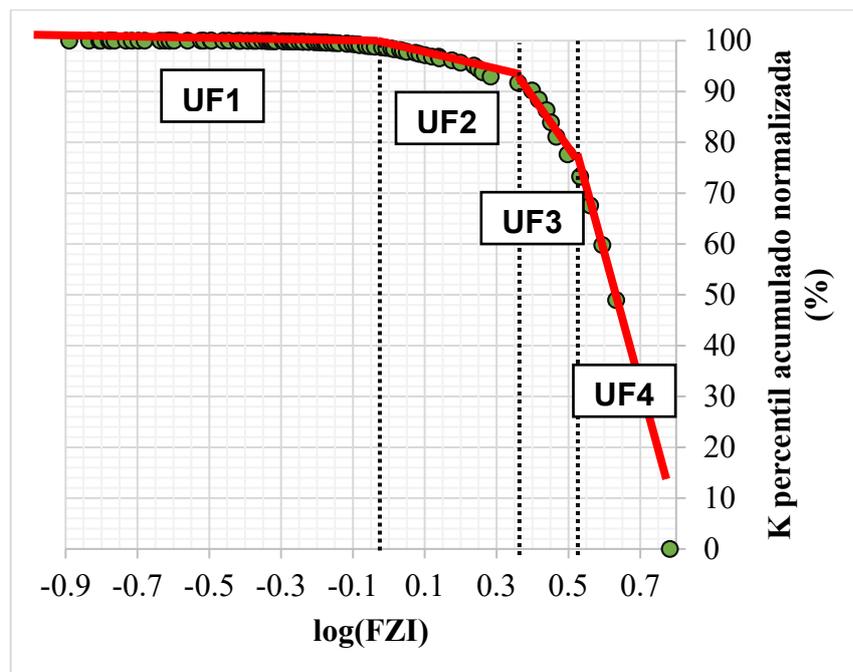


Figura 46. Gráfico de discretização das unidades de fluxo horizontal.

Na Tabela 4 são apresentados o *Cut-offs* de Log (FZI), FZI, RQI, ϕ_e e K discretizados para cada unidade de fluxo horizontal. Com estes, foi possível definir que a unidade de fluxo 1 (UF1) apresenta a piores propriedades petrofísicas para o fluxo e a unidade de fluxo 4 (UF4) é a melhor com respeito às outras 3 unidades. As cores para cada unidade de fluxo na Figura 47.

Tabela 4. *Cut-offs* de Log (FZI), FZI, RQI, ϕ_e e K discretizados para cada unidade de fluxo.

UF	UF1	UF2	UF3	UF4
Log(FZI)	< -0.1	-0.1 – 0.36	0.36 – 0.51	> 0.51
FZI (μm)	< 0.794	0.794 – 1.949	1.949 – 3.236	> 3.236
$\phi_E \left(\frac{\text{m}^3}{\text{m}^3} \right)$	0.069	0.086	0.099	0.14
K_{Hor} (mD)	1.47	4	23	294

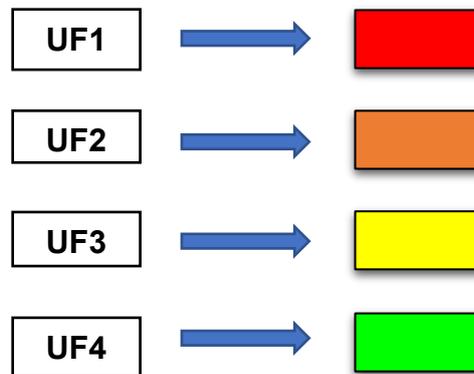


Figura 47. Cores para cada unidade de fluxo.

6.1.5. Comparações

Neste sub-estágio são apresentados gráficos entre propriedades petrofísicas (X, Y) e eletrofácies ou petrofácies como terceiro parâmetro (Z) (Figuras 48 a 51). É possível observar que não há um agrupamento de eletrofácies semelhantes, porém as petrofácies amostram tendências de agrupamento (círculos vermelhos). As comparações entre os modelos de

eletrofácies e a interpretação das lâminas delgadas pode ser observada na Figura 52. Por enquanto, a comparação entre os modelos de petrofácies e os dados laboratoriais de porosidade e permeabilidade na Figura 53. Como exemplo de comparação se apresenta na Figura 54 as eletrofácies para o poço 4 vs. as unidades de fluxo, tem um *zoom* que permite ver a detalhe a variabilidade vertical de eletrofácies, unidades de fluxo e como estão relacionadas. Na Figura 55 se apresenta o histograma de relacionamento eletrofácies com as unidades de fluxo. Desta maneira, também são feitas as petrofácies (Figura 56) e seu respectivo histograma (Figura 57).

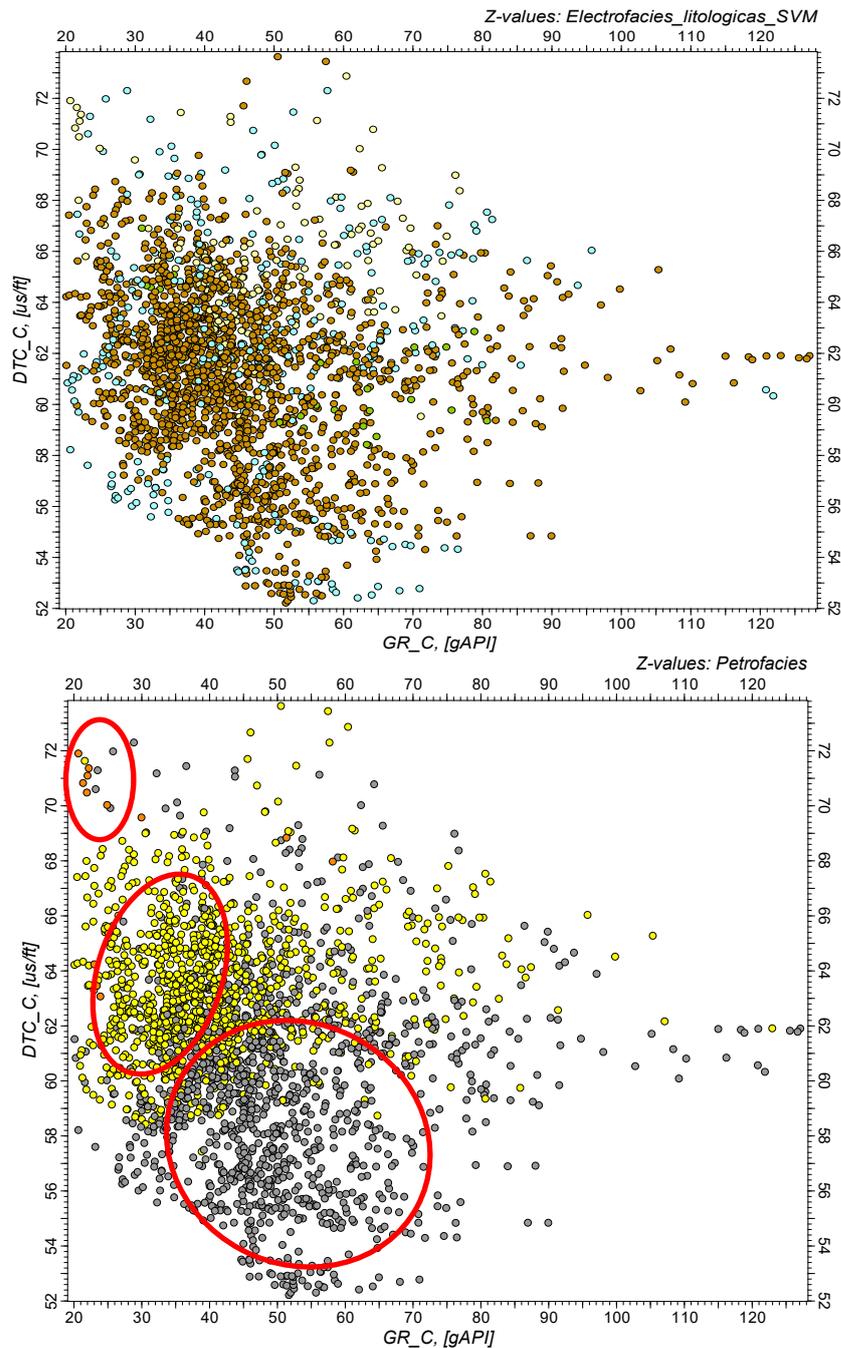


Figura 48. Comparação do DTC Vs GR para o poço 2.

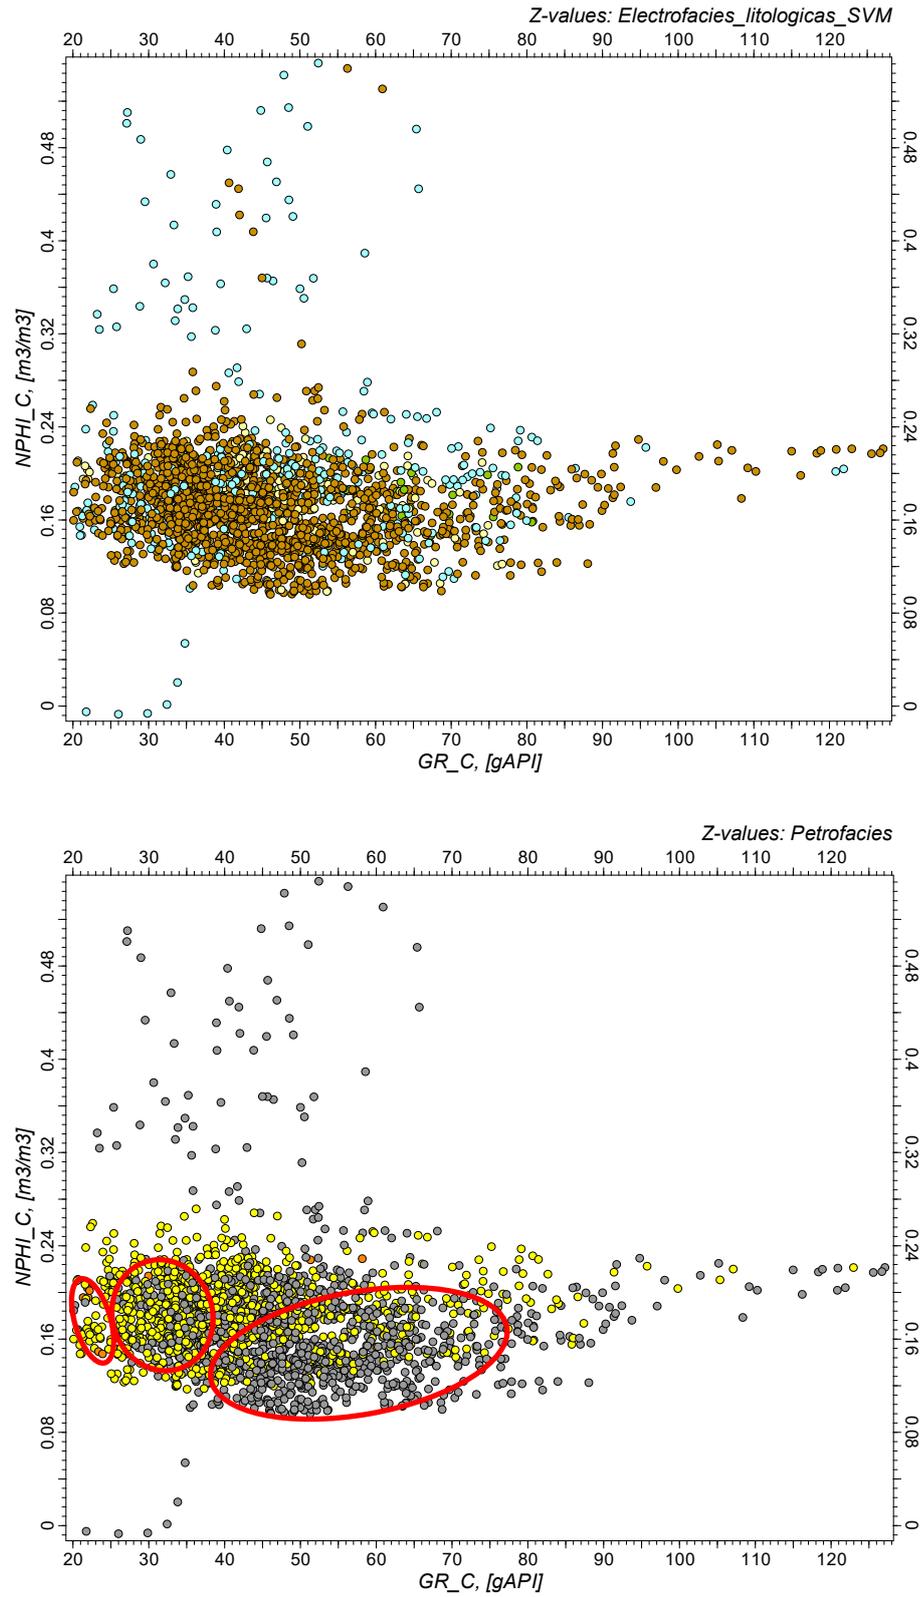


Figura 49. Comparação do NPHI Vs GR para o poço 2.

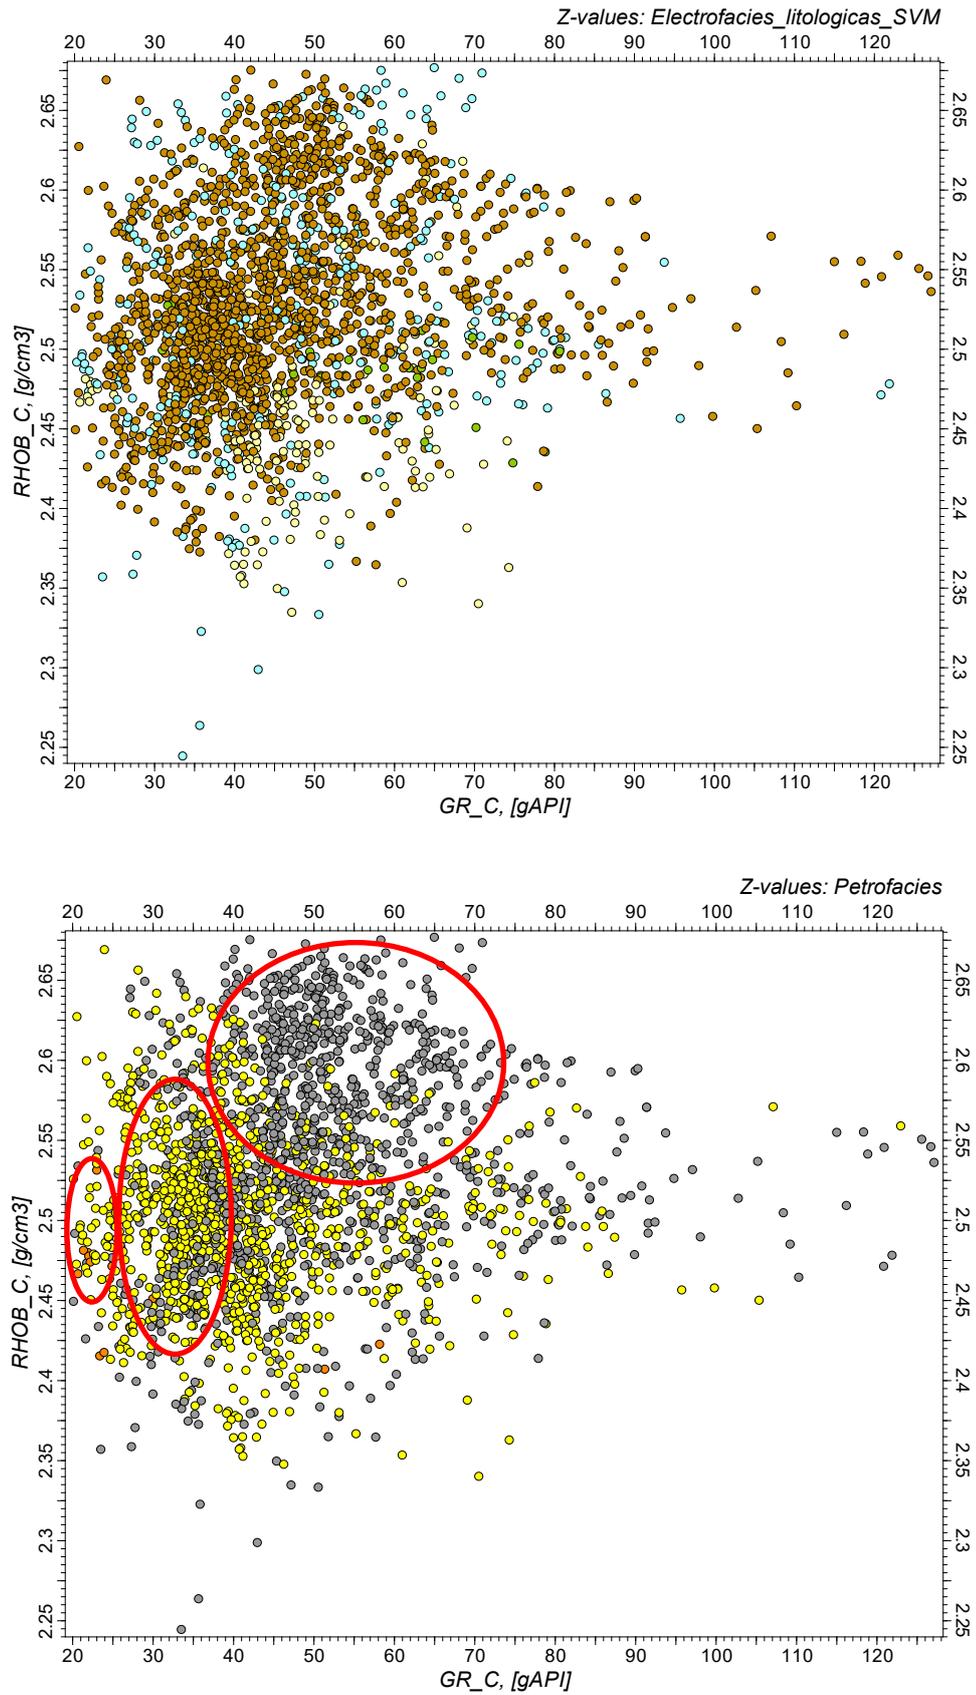


Figura 50. Comparação do RHOB Vs GR para o poço 2.

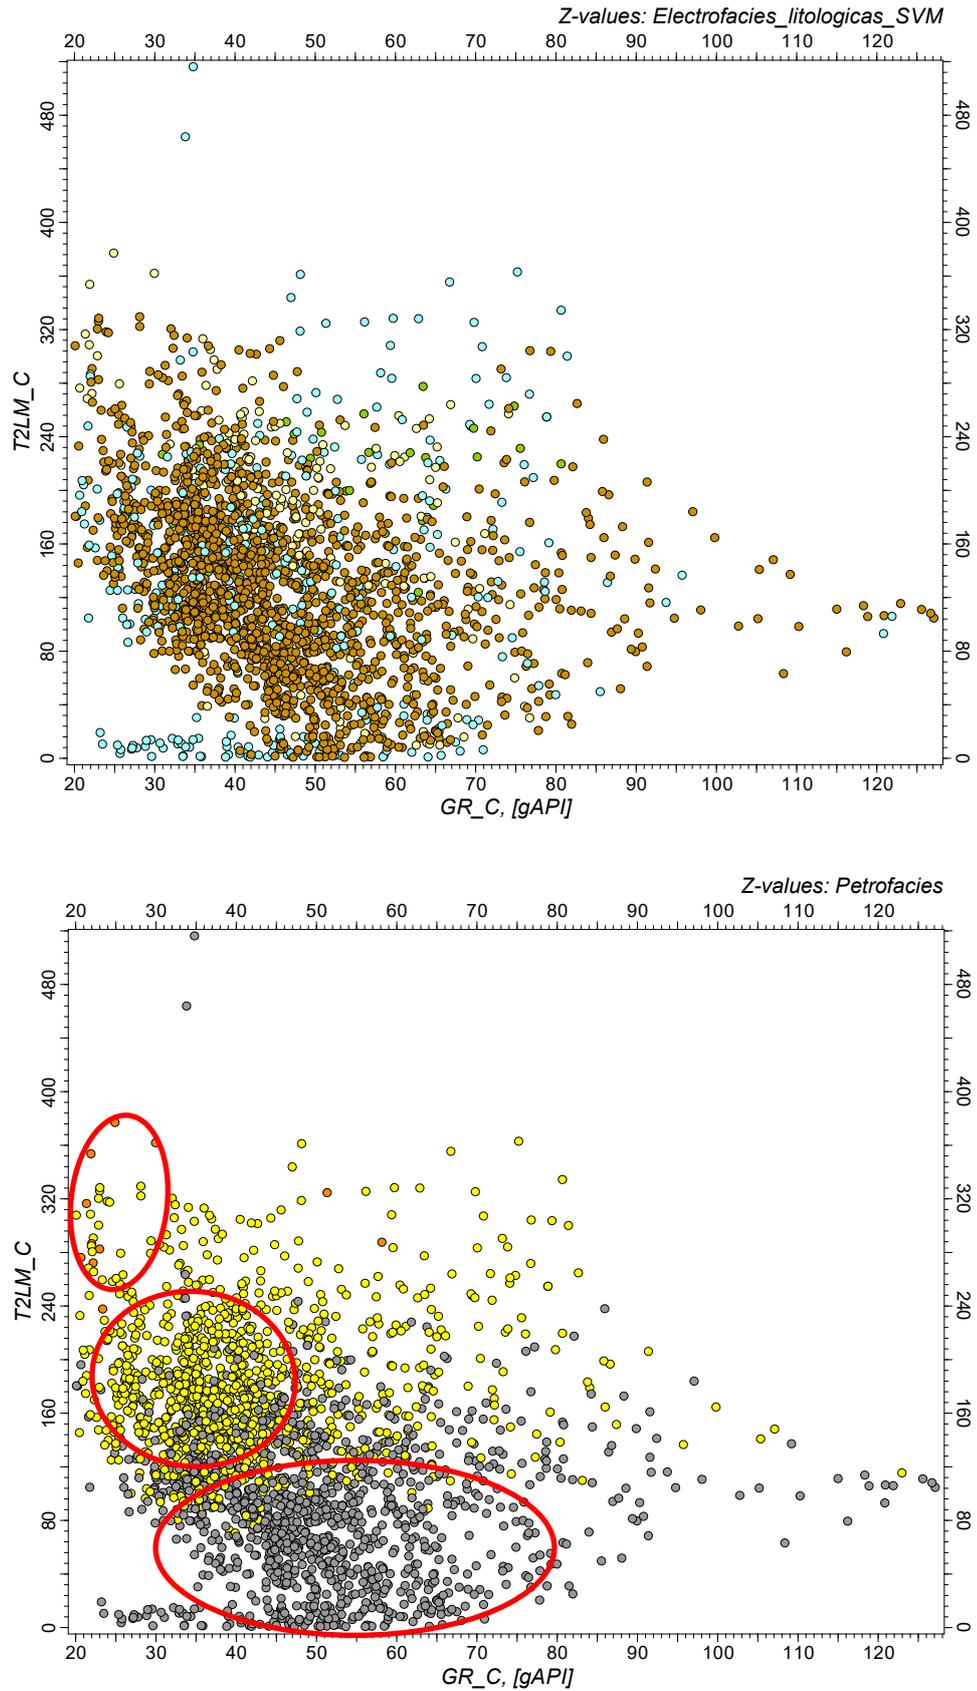


Figura 51. Comparação do T2LM Vs GR para o poço 2.

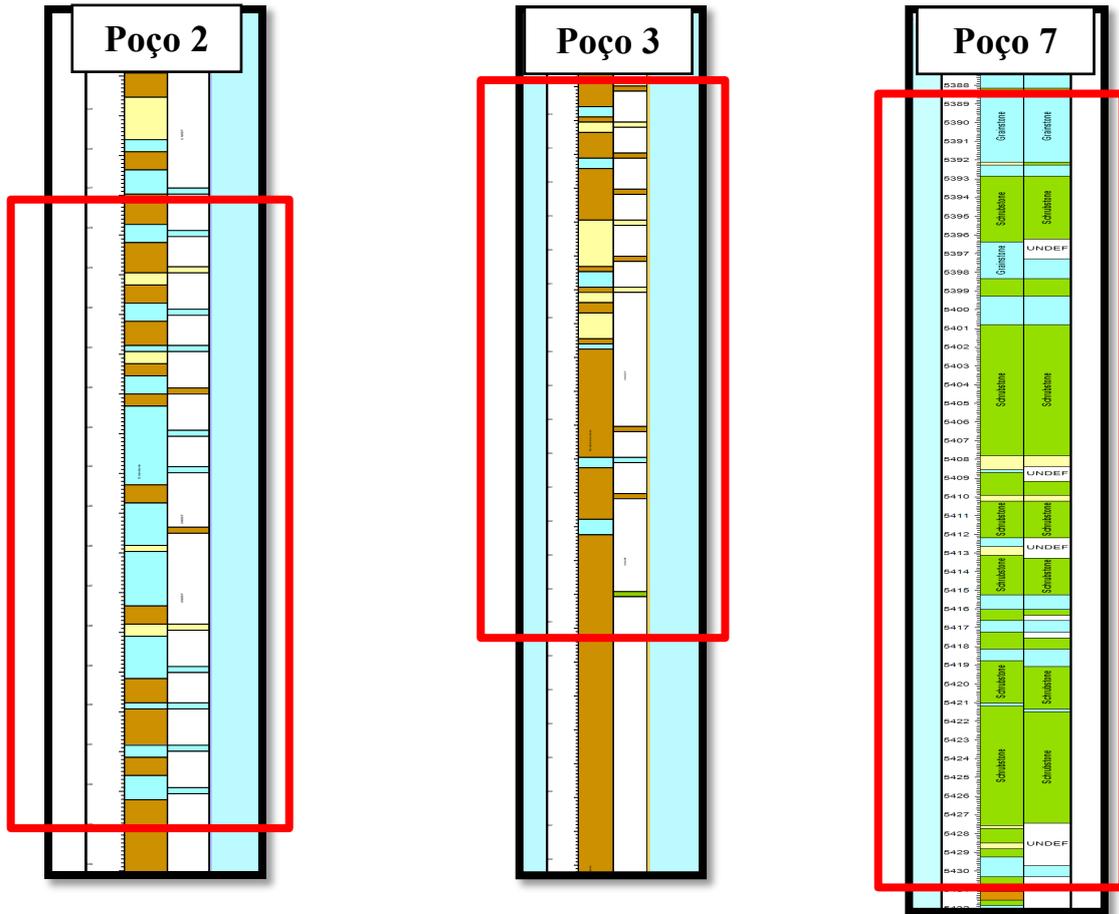


Figura 52. Comparações entre eletrofácies previstas e lâminas delgadas para os poços 2, 3 e 7.

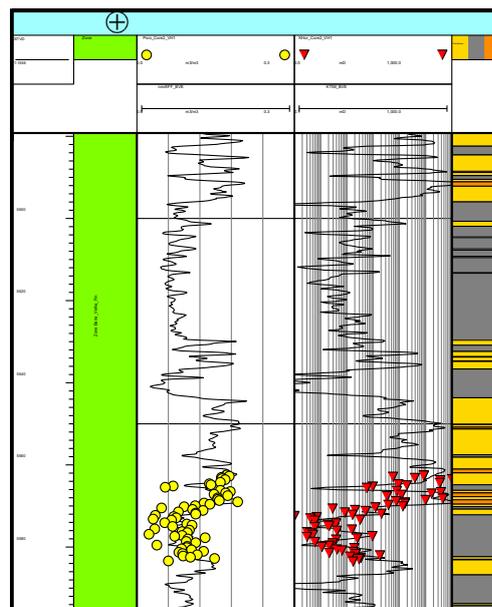


Figura 53. Comparação petrofácies Vs dados laboratoriais de PHIE e KTIM para o poço 4.

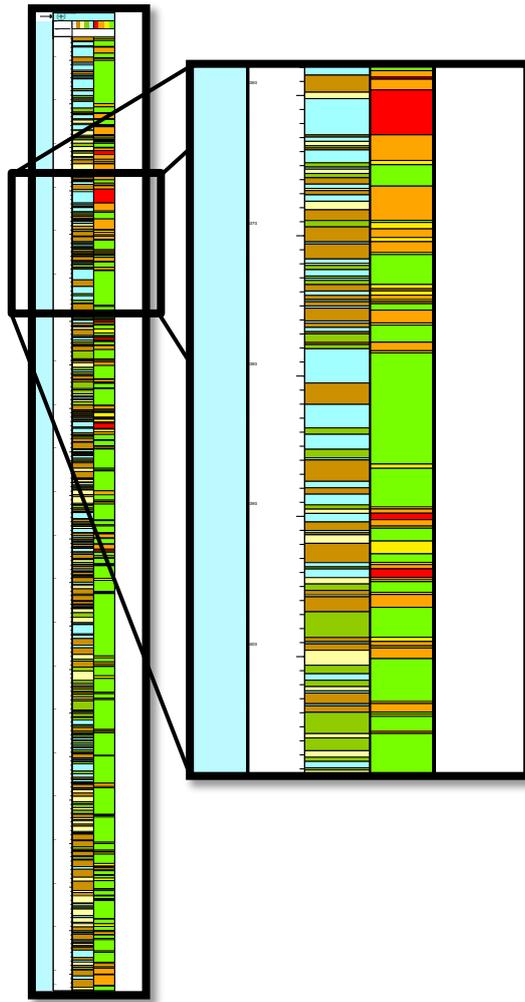


Figura 54. Comparação de eletrofácies Vs unidades de fluxo para o poço 4.

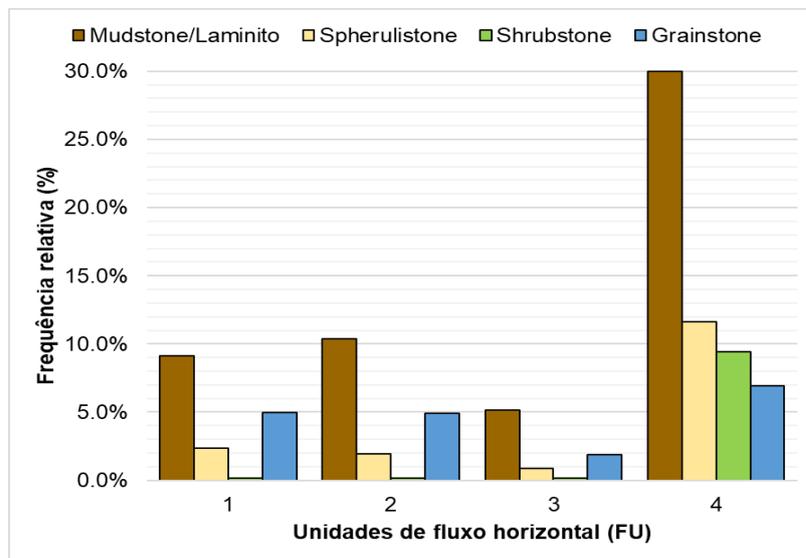


Figura 55. Histograma de relacionamento entre eletrofácies e unidades de fluxo.

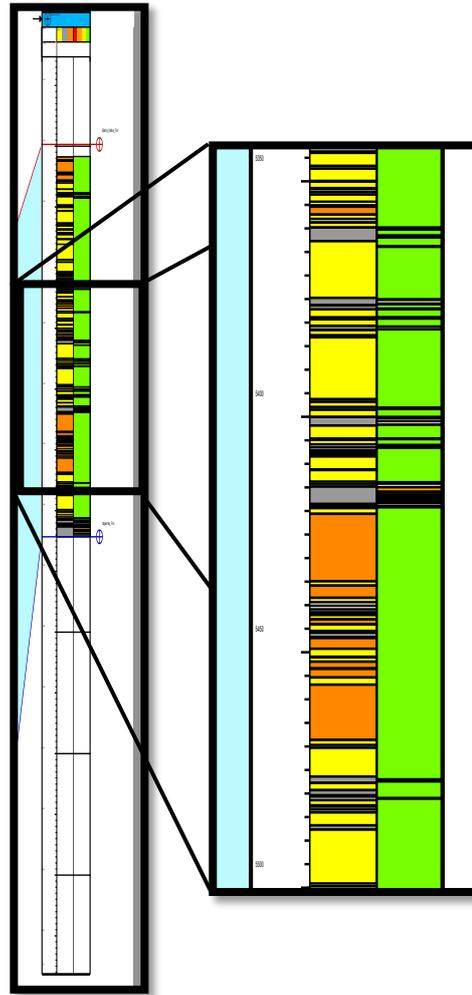


Figura 56. Comparação de eletrofácies Vs unidades de fluxo para o poço 8.

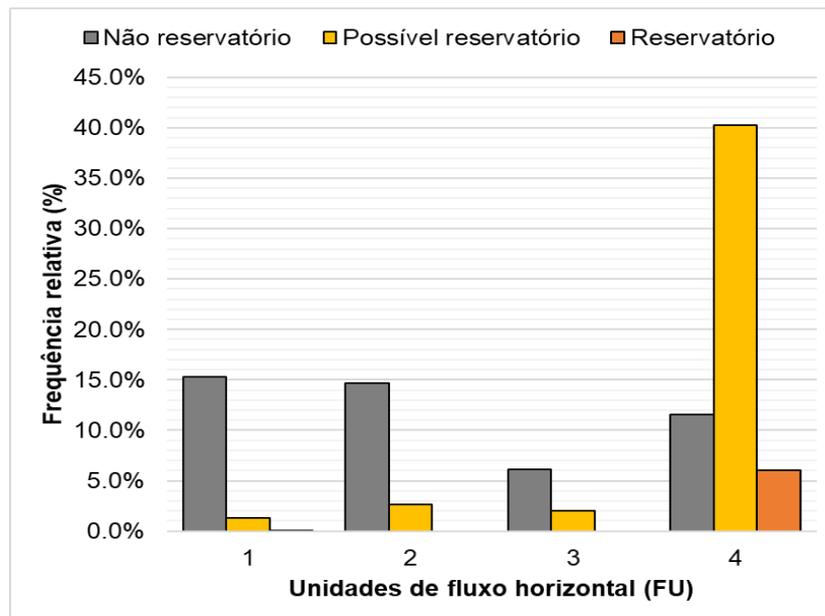


Figura 57. Histograma de relacionamento entre petrofácies e unidades de fluxo.

6.2. Estágio 2: filtros, atributos e interpretação sísmica.

6.2.1. Amarração sísmica-poço.

Inicialmente a sísmica concedida pela ANP está em tempo ms TWT (MIG-FIN), os poços foram criados com sua respectiva localização espacial no polígono referente aos campos de Berbigão, Sururu e Atapu, e desvios de poço respectivamente (Figura 58).

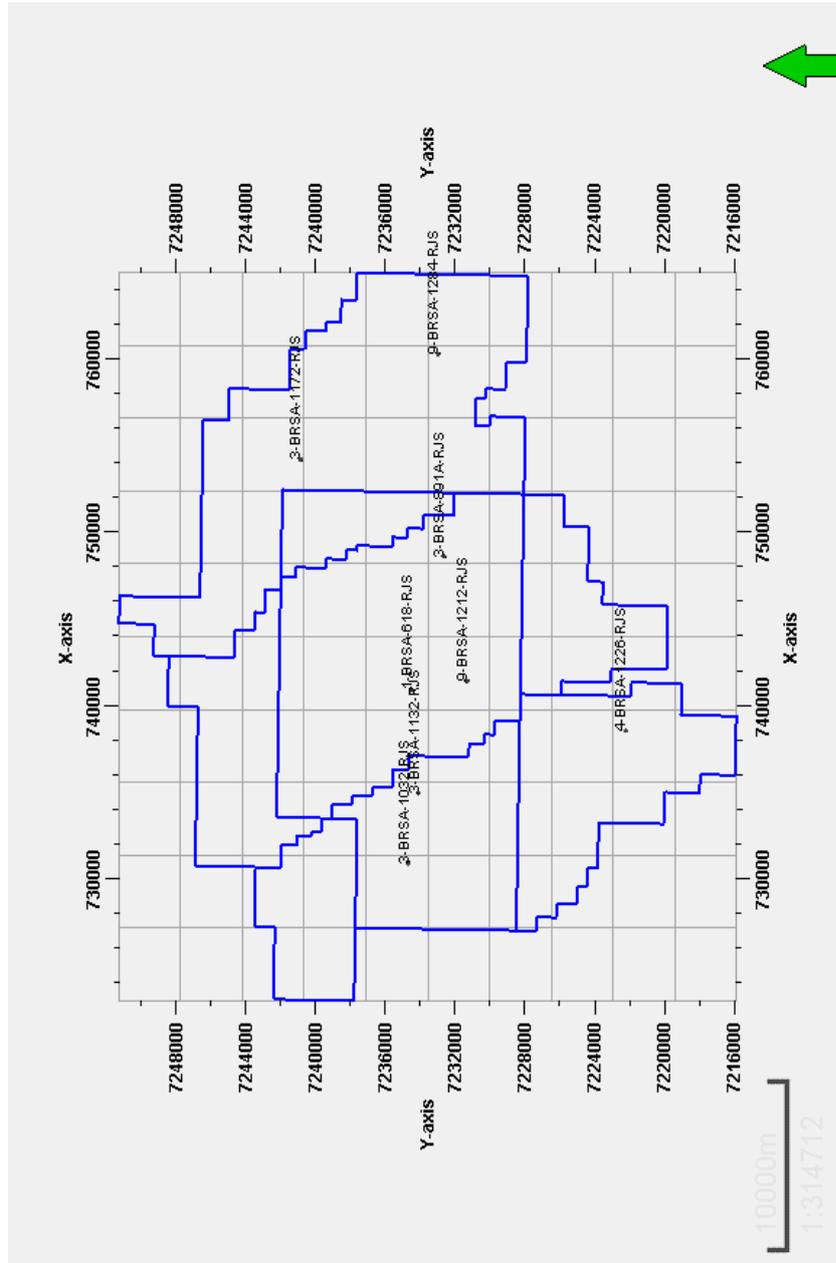


Figura 58. Poços localizados com seus respectivos desvios espacialmente localizados.

Utilizando o módulo de *Well-Tie* em PETREL segue-se os passo nas Figuras 59 a 62.

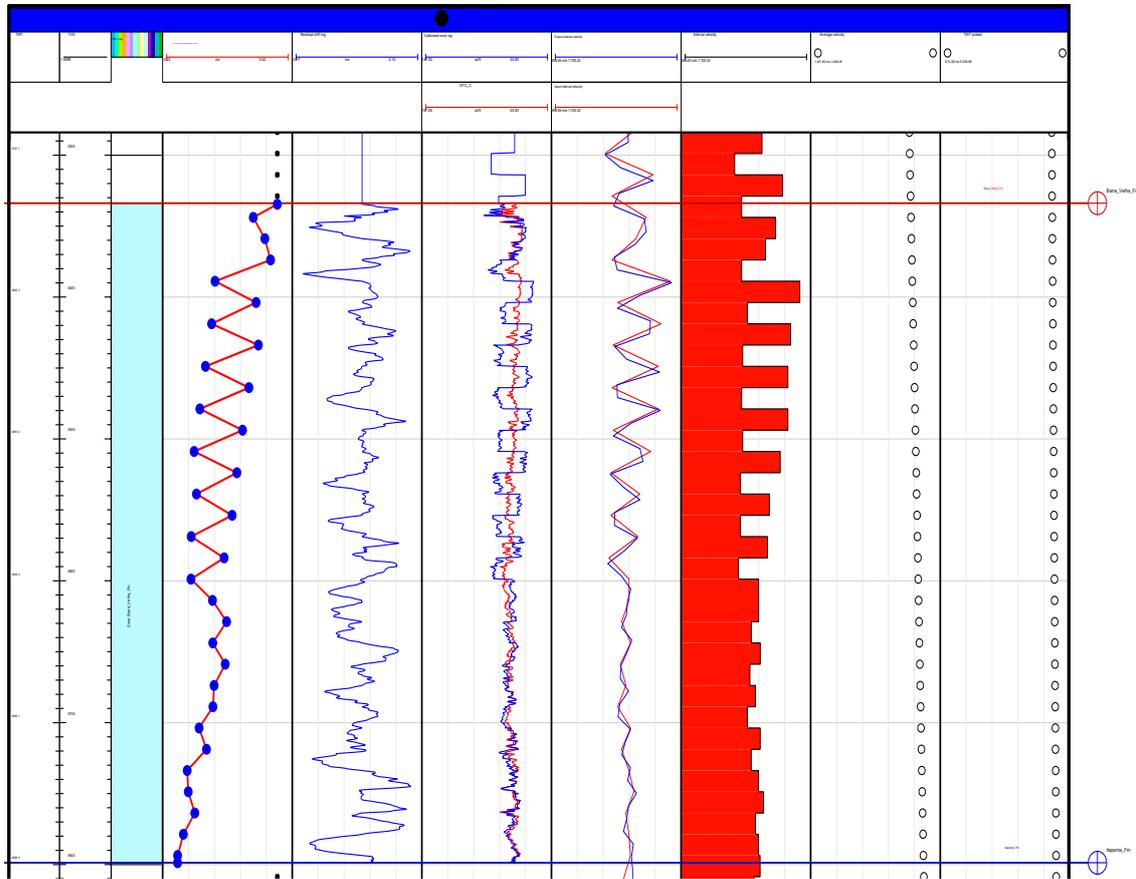


Figura 59. Calibração do perfil sônico com os *Checkshots*.

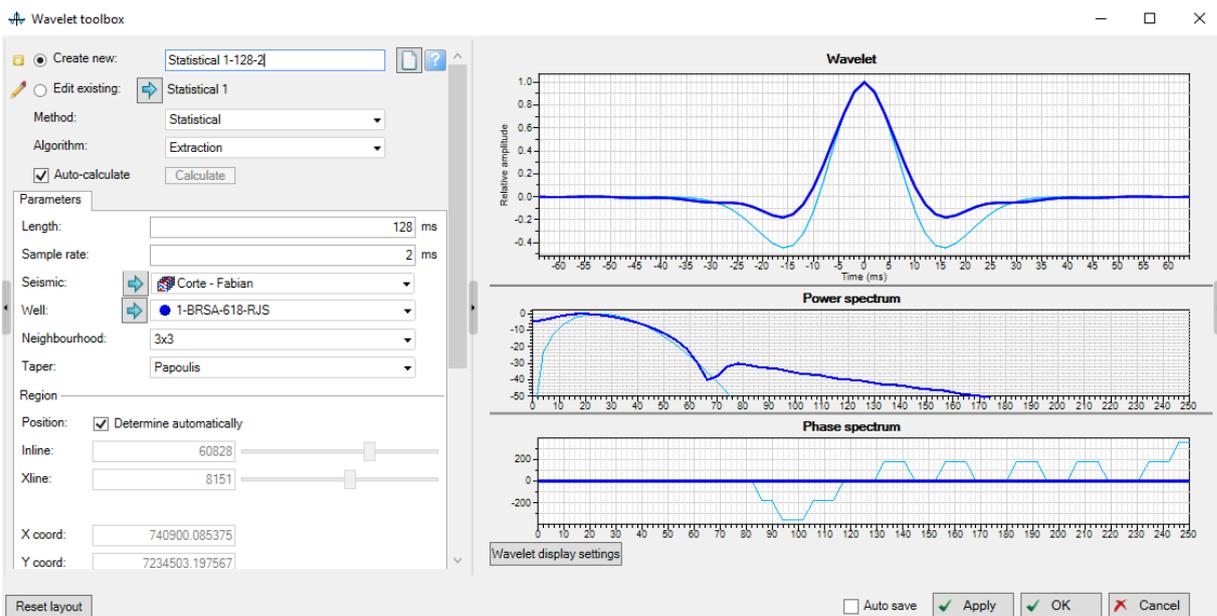


Figura 60. Criação da traça sintética por método estatístico e 0° de fase.

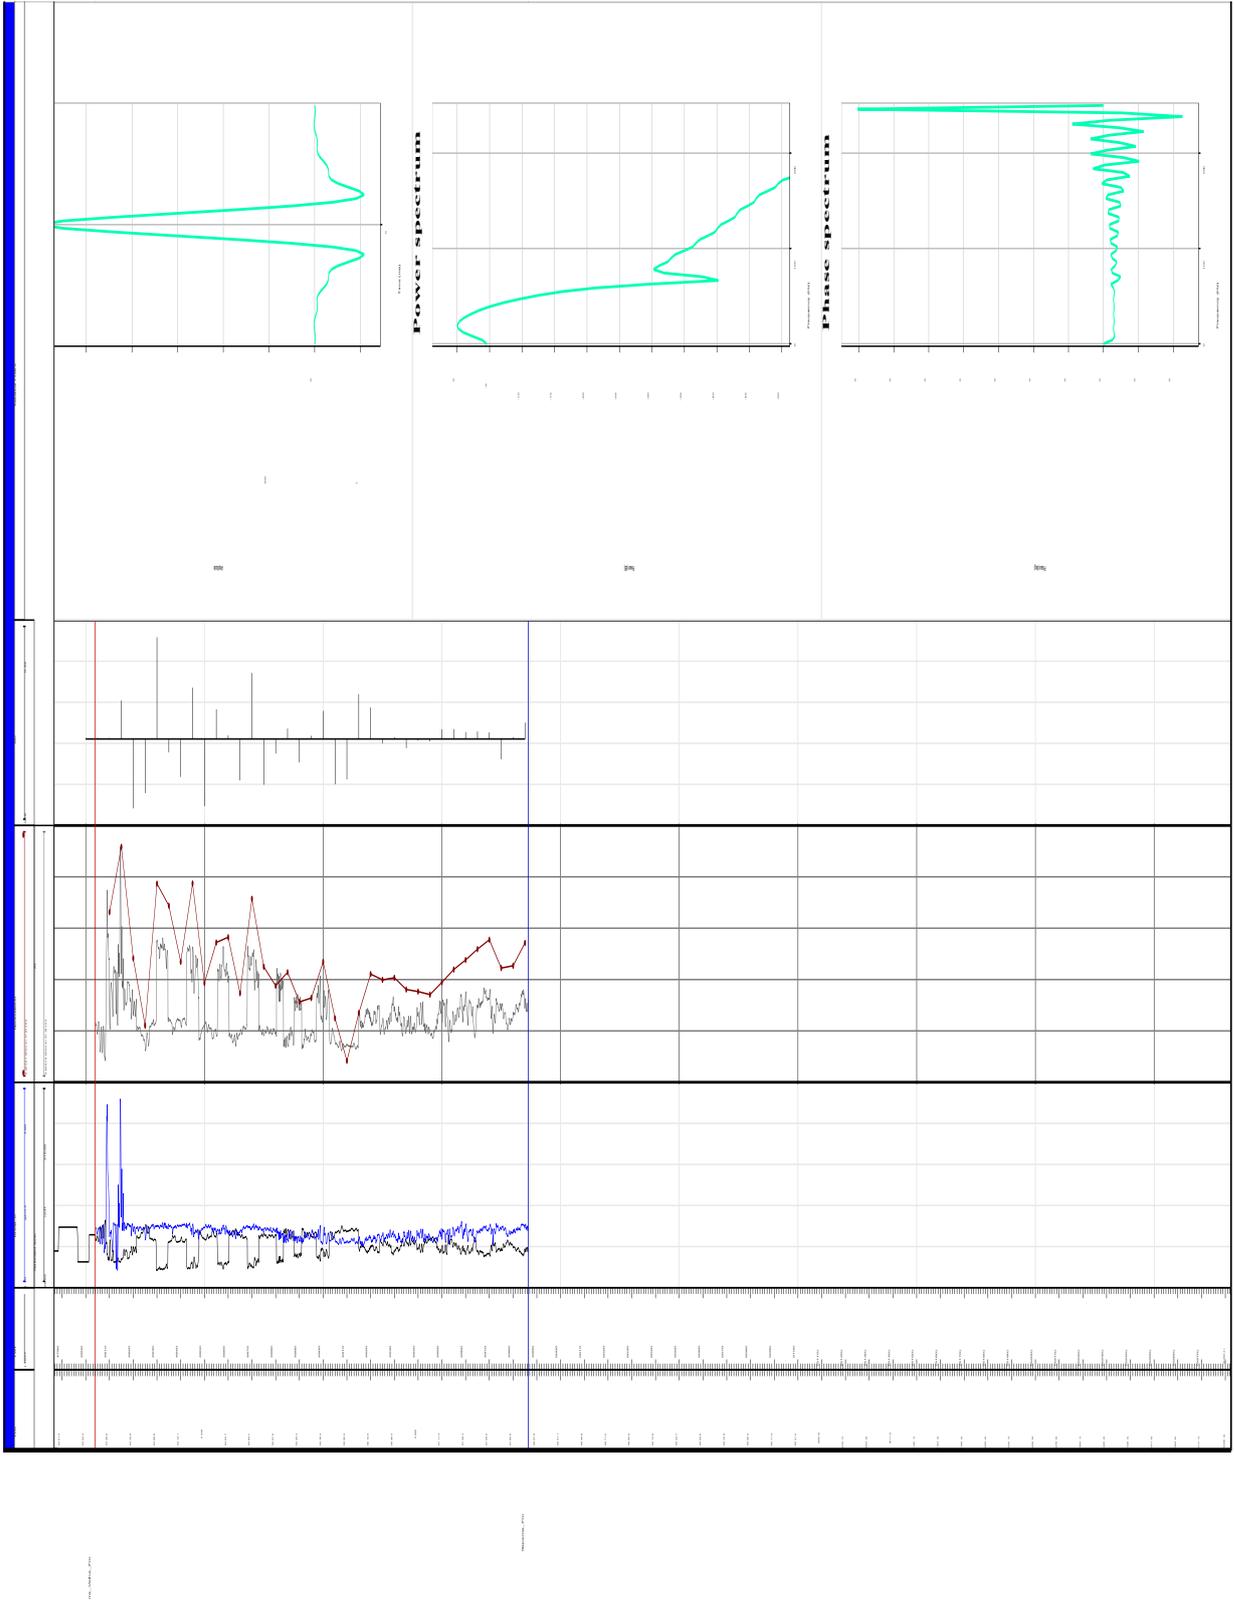


Figura 61. Coeficientes de reflexão para a Formação Barra Velha.

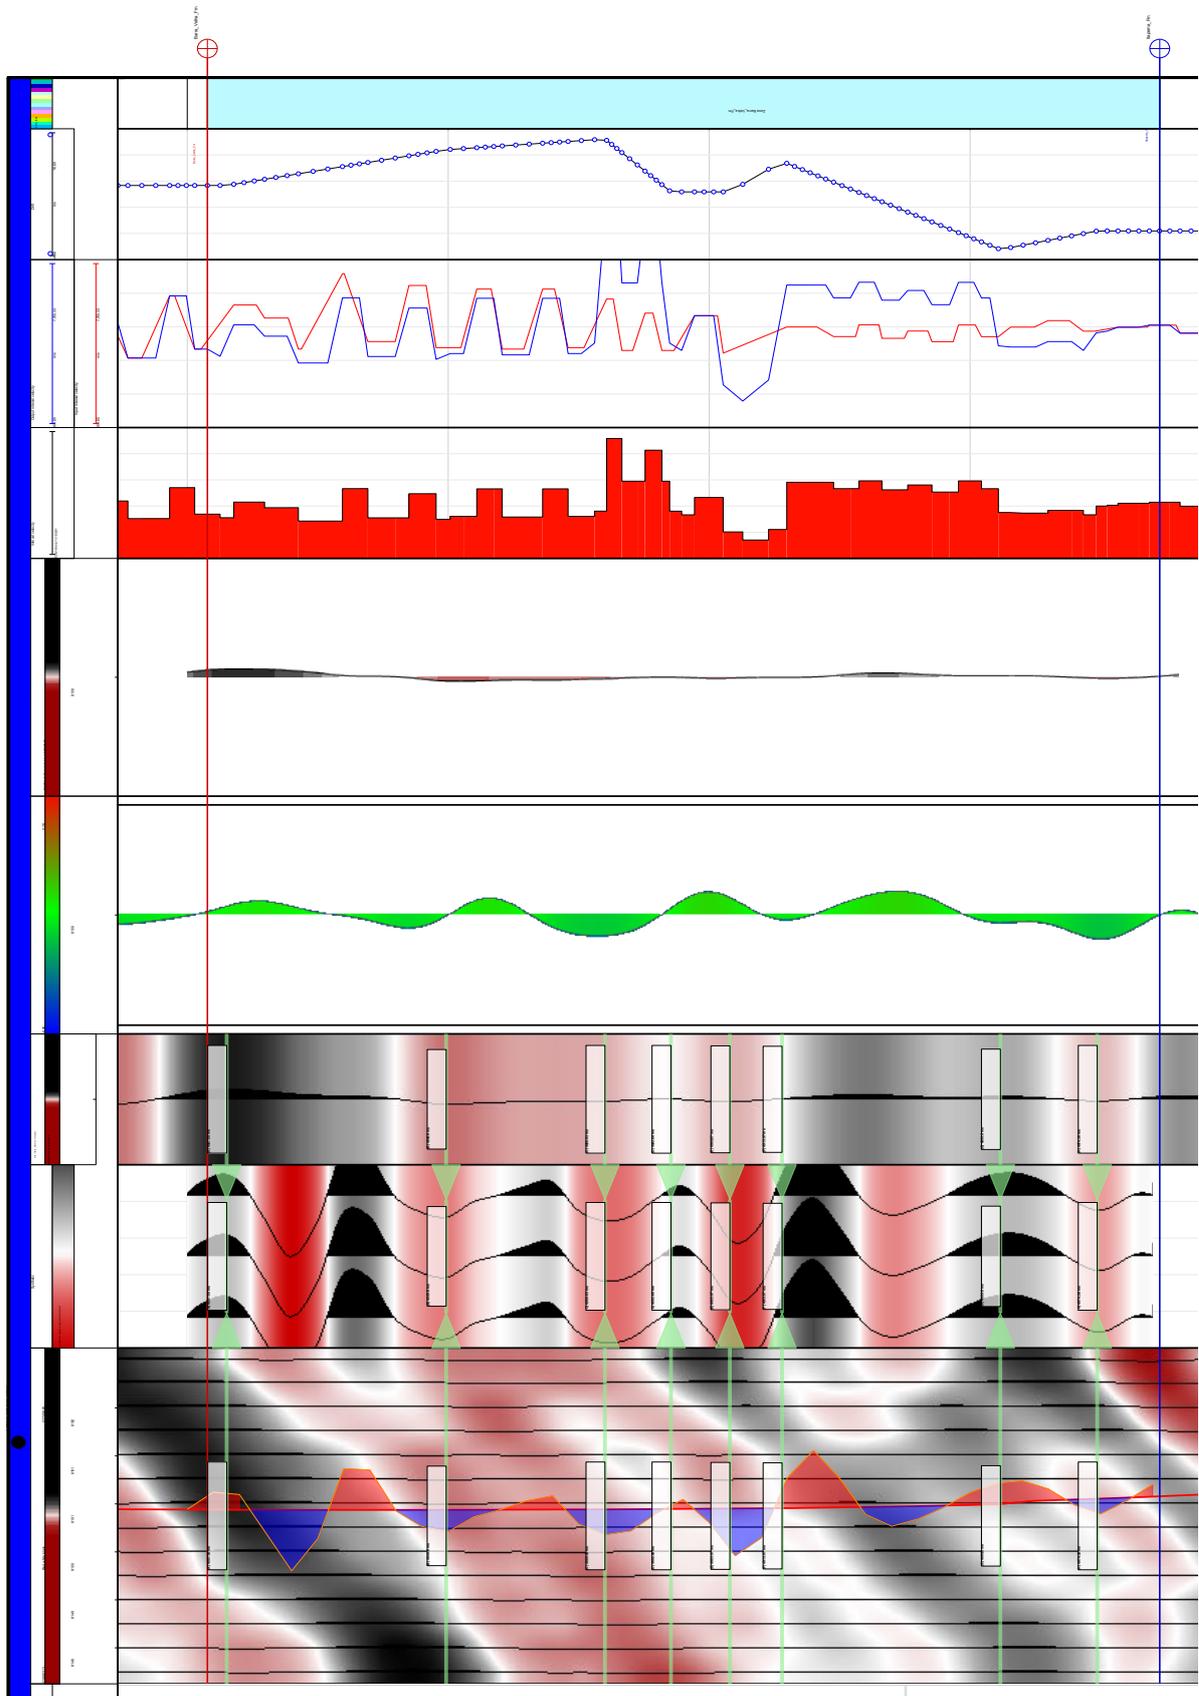


Figura 62. Exemplo de amarre sísmica-poço manual para o poço 1.

6.2.2. Aplicação de filtros e atributos sísmicos

Para a interpretação sísmica foram utilizados filtros e atributos sísmicos. Isto, devido que o dado sísmico apresentou muito ruído, dificultando a interpretação das falhas e horizontes na área. Portanto como resultado inicialmente implementando o *Dip Steered Median Filter* (DSMF), obtendo-se assim uma suavização da imagem sísmica na Figura 63, e conseguindo diferenciar as diferentes camadas do Pré-sal. Posteriormente foi aplicado o *Fault Enhancement Filter* (FEF), o que permite observar uma melhor continuidade das camadas e destacar ainda mais onde não estavam, obtendo um bom suavizado e continuidade da imagem na Figura 64. Por último, foi utilizado o atributo sísmico *Thinned Fault Likelihood* (TFL), que nos permitiu observar melhor as falhas maiores e mais representativas. A imagem sísmica obtida com o atributo sísmico TFL foi sobreposta a imagem sísmica com o filtro FEF, permitindo assim a interpretação das falhas (Figura 65).

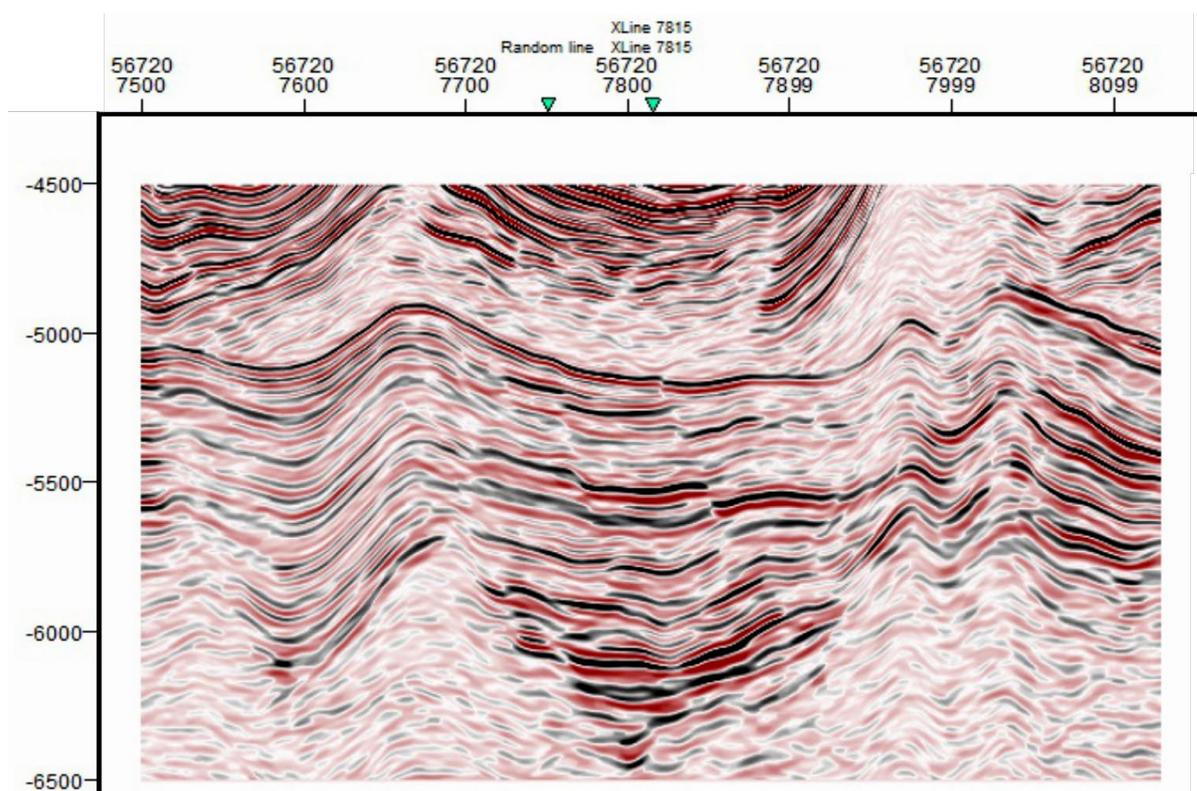


Figura 63. Aplicação de filtro DSMF em um *in-line*.

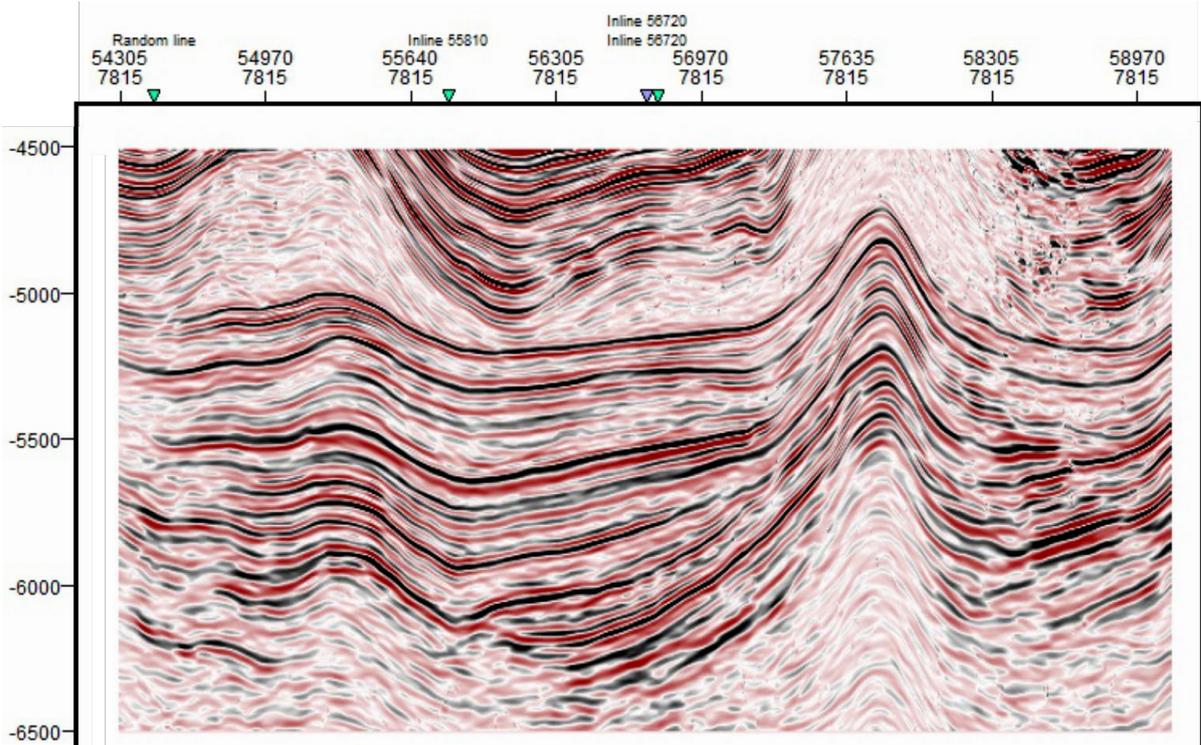


Figura 64. Aplicação do FEF em um *cross-line*.

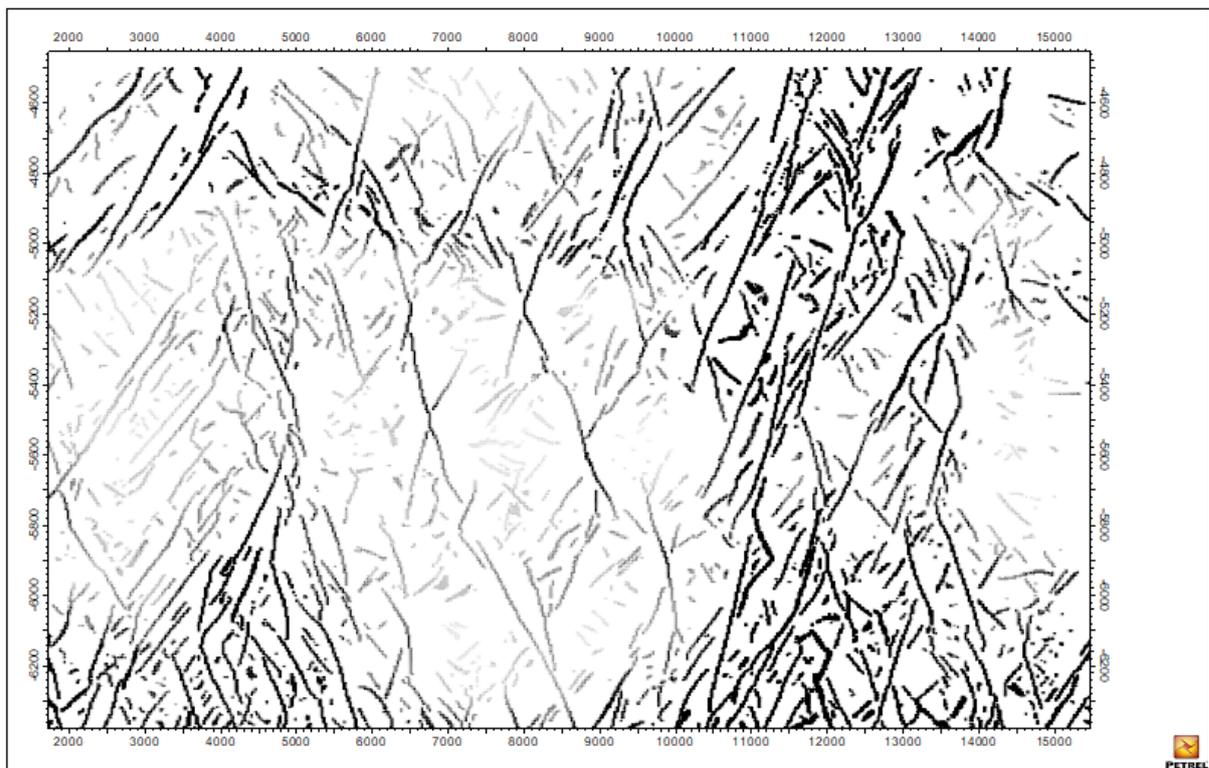


Figura 65. Aplicação do atributo sísmico TFL em um *in-line*.

6.2.3. Interpretação sísmica

Como resultado da interpretação das falhas na área se tiveram 312 falhas interpretadas em toda a extensão. Estas falhas não foram muito extensas, como um valor médio de 50 m (Figura 66). O reservatório é delimitado na base pelo horizonte correspondente ao topo da Formação Itapema (Figura 68) e no topo pelo horizonte correspondente ao topo da Formação Barra Velha (Figura 67).

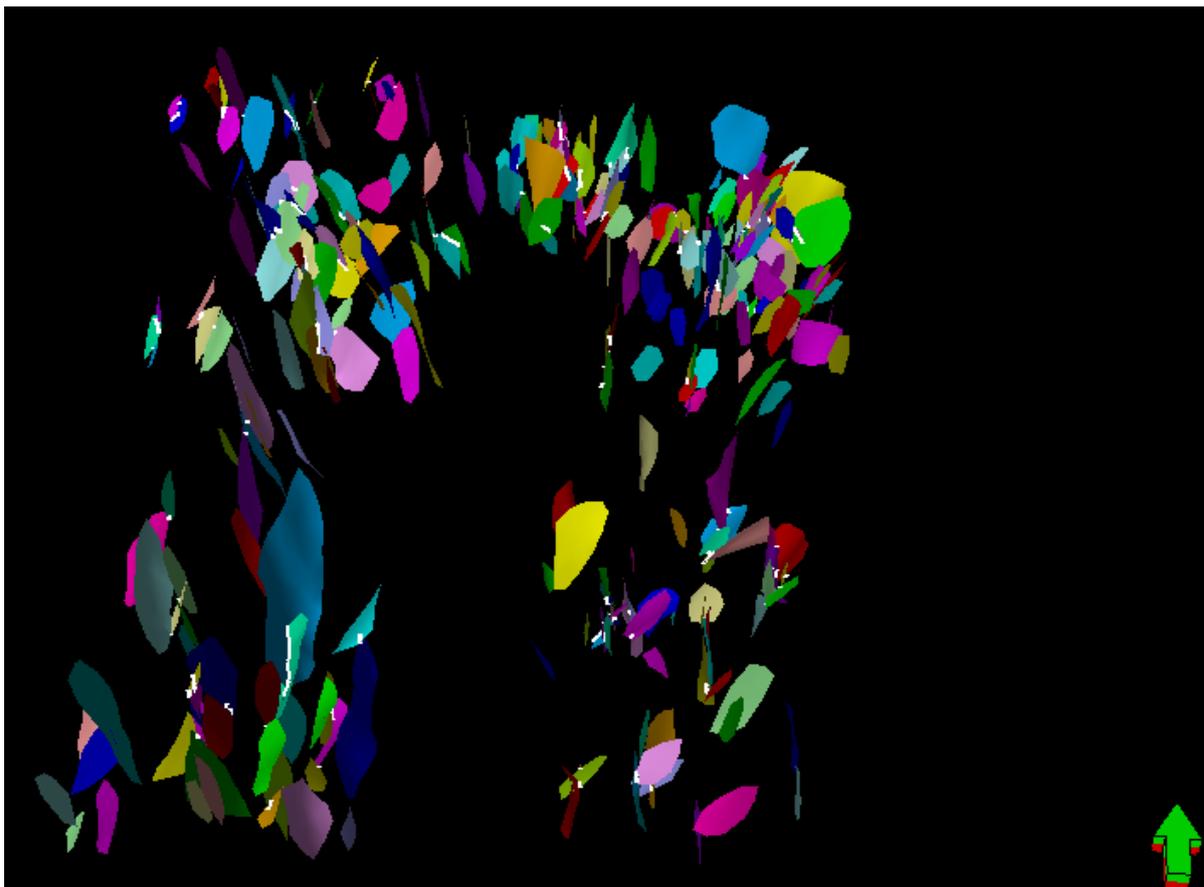


Figura 66. Interpretação de falhas nos campos Berbigão, Sururu e Atapu.

6.3. Estágio 3: modelagem estrutural 3D

6.3.1. Modelo estrutural 3D

O modelo estrutural em 3D foi criado a partir dos horizontes e falhas interpretados. A partir desse modelo inicial (esqueleto) foi possível estabelecer o número de células (Figura 69). Esse modelo abrange a área correspondente aos campos de Berbigão, Sururu e Atapu.

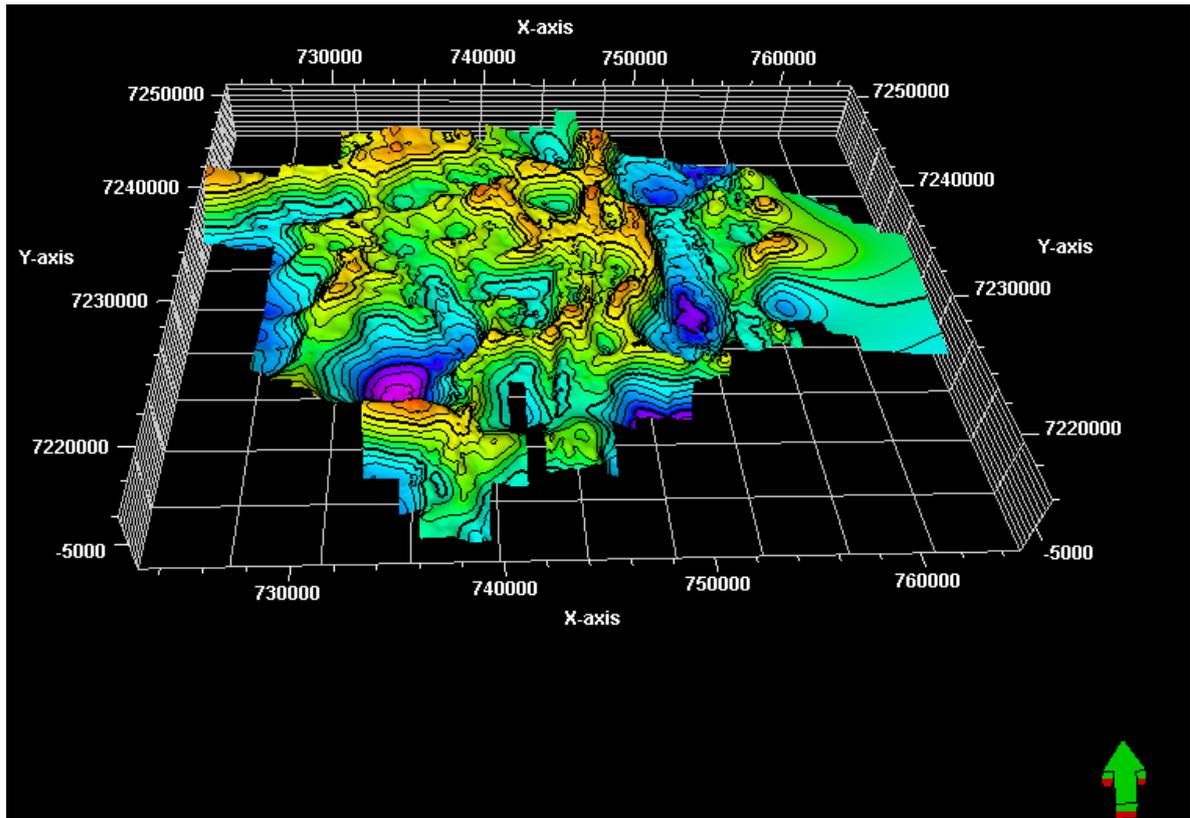


Figura 67. Interpretação do horizonte da Formação Barra Velha.

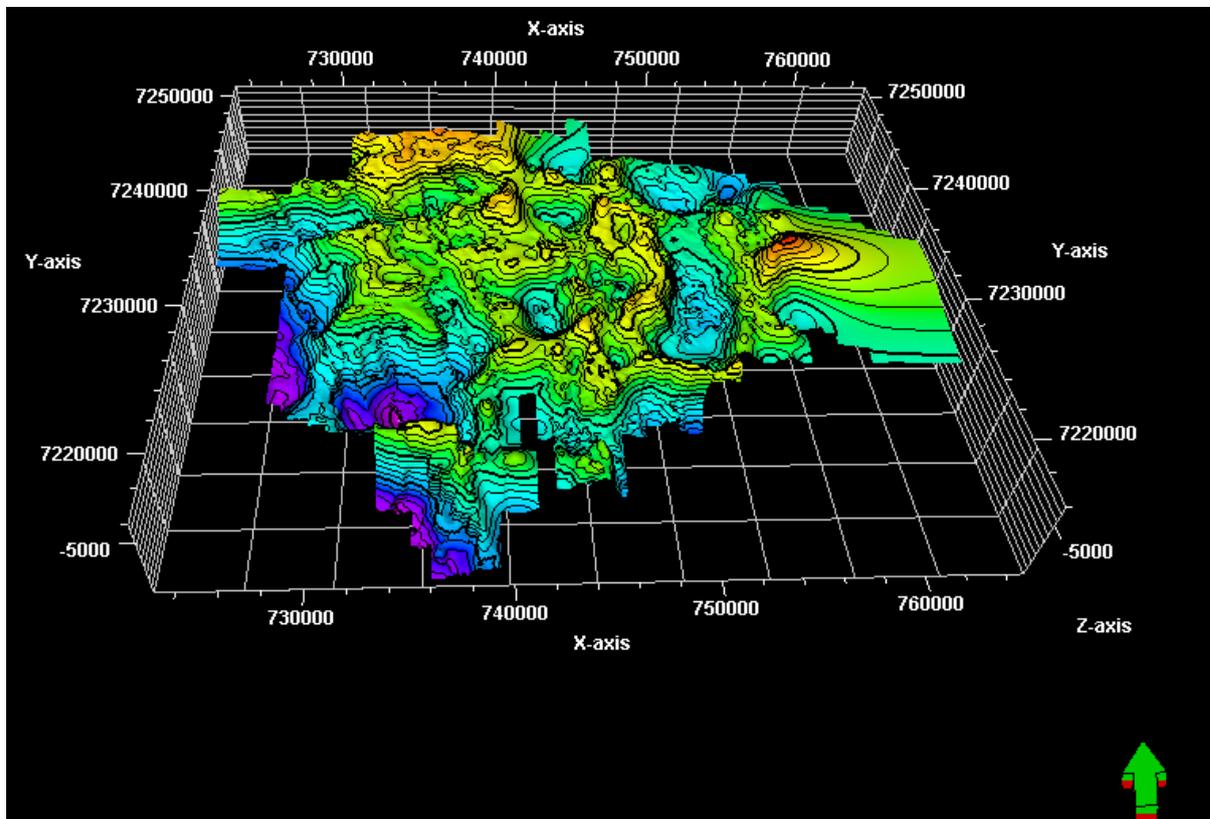


Figura 68. Interpretação do horizonte da Formação Itapema.

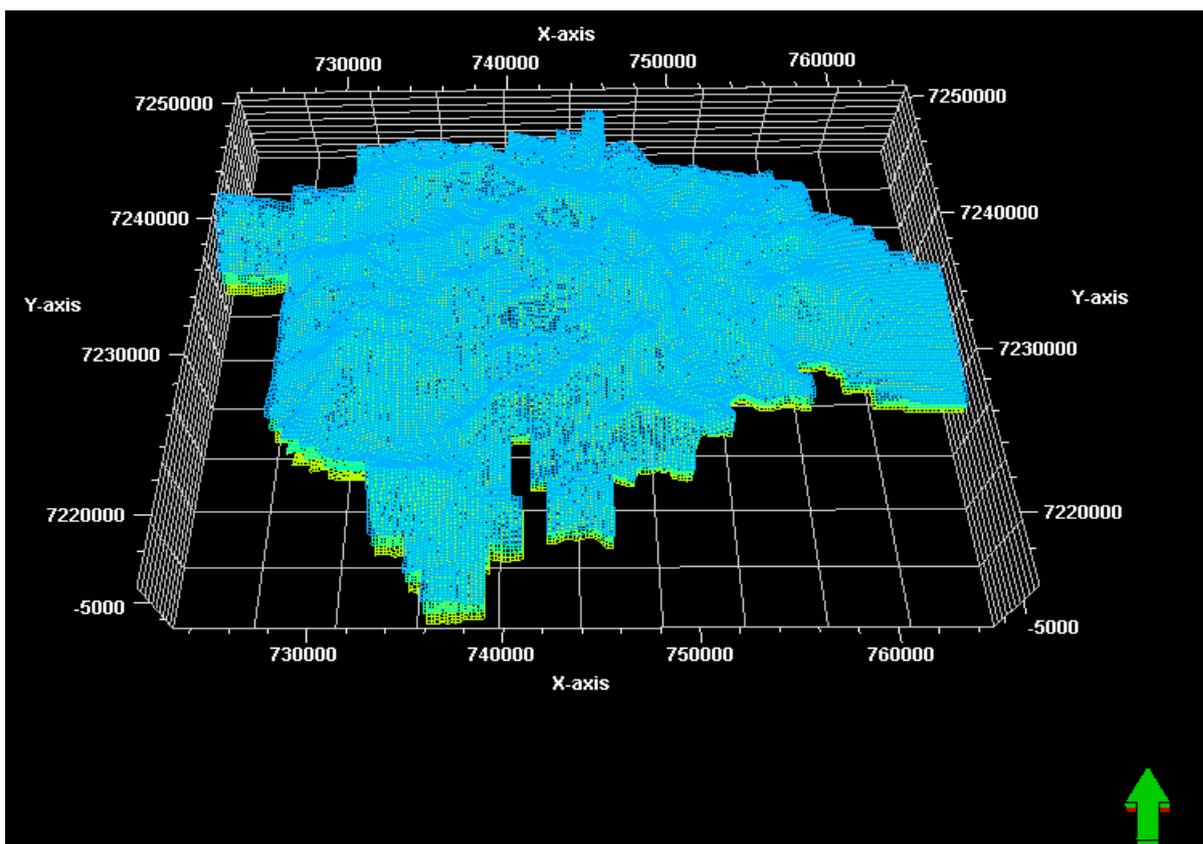


Figura 69. Esqueleto da malha estrutural 3D ou Grid 3D.

6.3.2. Geoestatística

Um modelo estrutural 3D foi gerado preenchido com eletrofácies (*SVM Radial*) e Petrofácies (*K-Means Clustering*). Foram obtidas as distâncias entre os diferentes poços e obteve-se uma distância média, que representará a anisotropia de propagação do modelo de eletrofácies e petrofácies ao longo do volume estrutural (Tabela 5), obtendo um valor médio de 14548.84 m. Na Figura 70 é possível observar o modelo 3D com as eletrofácies (*Mudstone-Laminite*, *Spherulitestone*, *Shrubstone* e *Grainstone*). Na Figura 71 é possível ver o modelo lateralmente, mostrando as diferentes camadas que foram obtidas a partir do *up-scaling* do modelo de eletrofácies e posterior propagação geoestatística ao longo de todo o modelo estrutural 3D, como observado em secção estratigráfica na Figura 72.

O *up-scaling* e propagação por meio de geoestatística também foi feito para o modelo de petrofácies, Figuras 73 e 74. Na Figura 75 pode-se observar a mesma secção estratigráfica utilizada para representar as eletrofácies. As petrofácies são muito mais contínuas do que as eletrofácies, implicando que tem uma maior relação com as unidades de fluxo de boa qualidade (UF4 e UF3) fundamental para entender o comportamento de fluxo na área.

Tabela 5. Listagem de distâncias entre poços na área de estudo.

POÇO	1	2	3	4	5	6	7	8
1	0	7951.96	10044.1	5975.48	14784.9	12476.6	3202.26	19465
2	7951.96	0	17897.9	13781.2	9953.84	14509.4	7329.62	11674.5
3	10044.1	17897.9	0	4118.92	24171.2	14649.2	11098.2	29499.1
4	5975.48	13781.2	4118.92	0	20442	12424.2	7070.35	25397.3
5	14784.9	9953.84	24171.2	20442	0	24374.1	15975	9969.52
6	12476.6	14509.4	14649.2	12424.2	24374.1	0	9541.15	24284.4
7	3202.26	7329.62	11098.2	7070.35	15975	9541.15	0	18951.5
8	19465	11674.5	29499.1	25397.3	9969.52	24284.4	18951.5	0

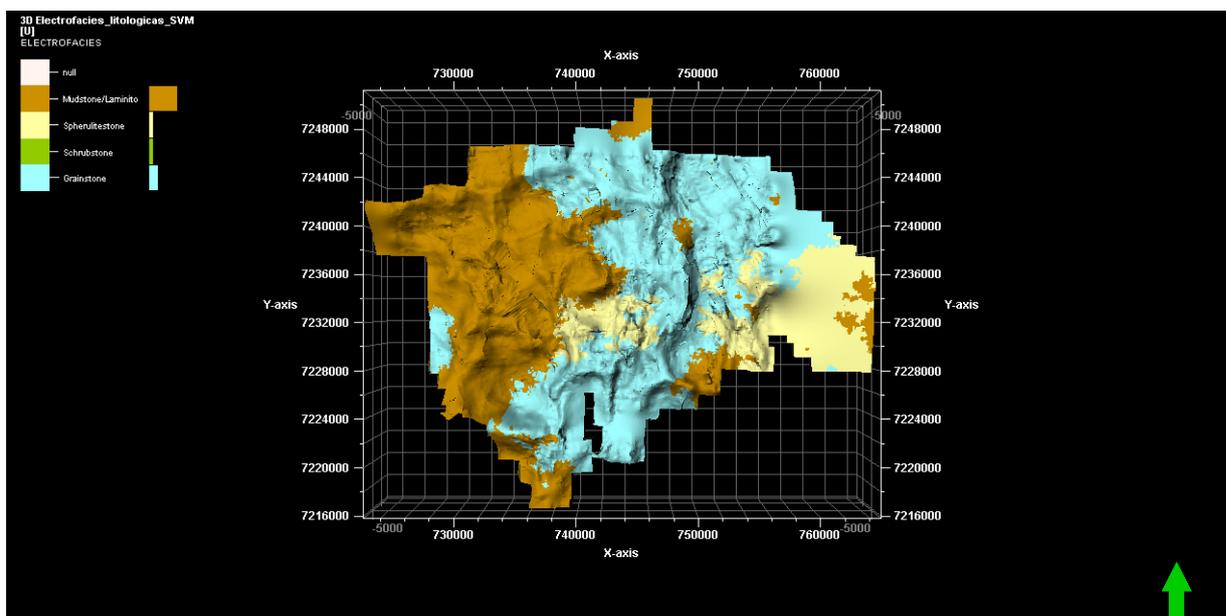


Figura 70. Vista aérea geral da propagação de eletrofácies SVM por meio de geoestatística.

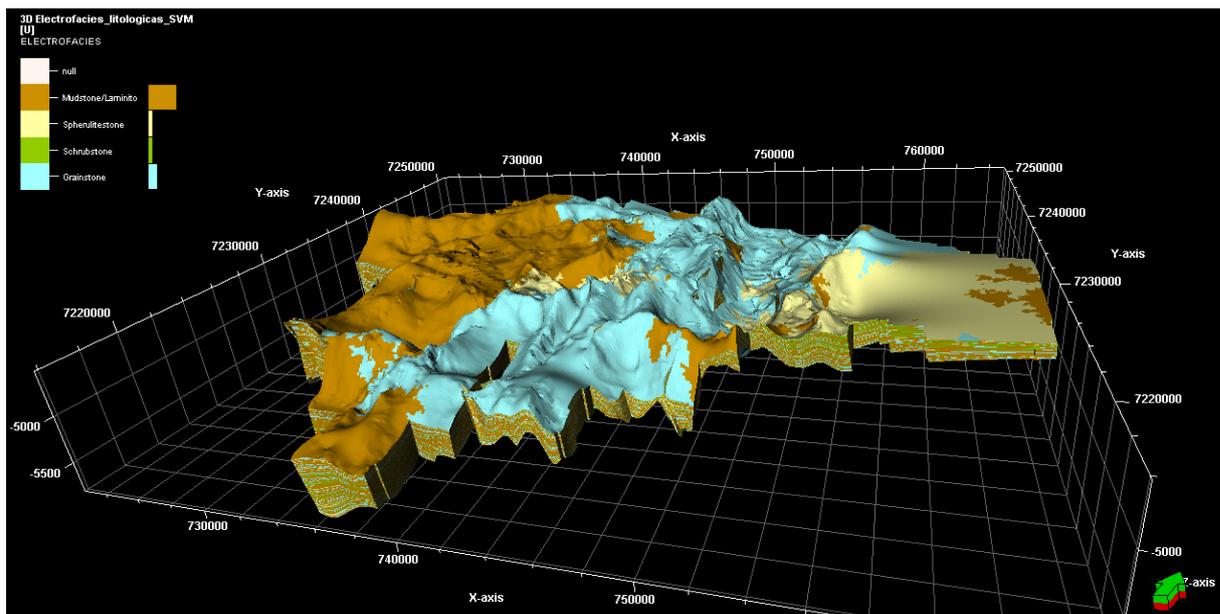


Figura 71. Vista lateral geral da propagação de eletrofácies SVM por meio de geoestatística.

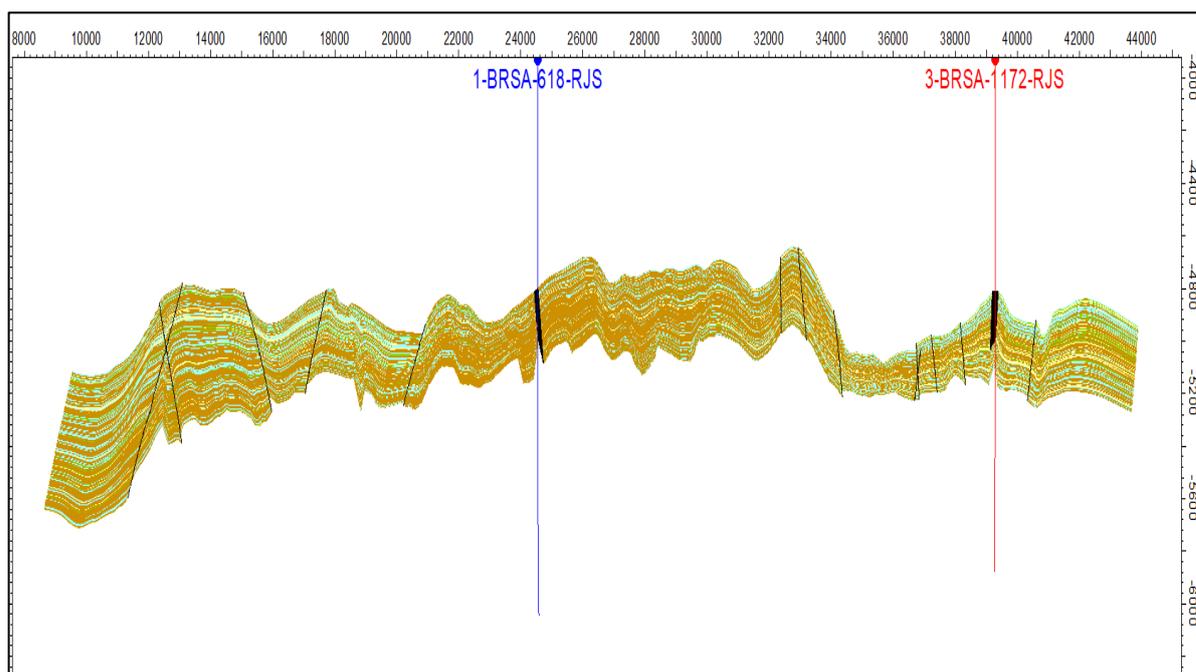


Figura 72. Seção estratigráfica entre 2 poços da propagação de eletrofácies por meio de geoestatística.

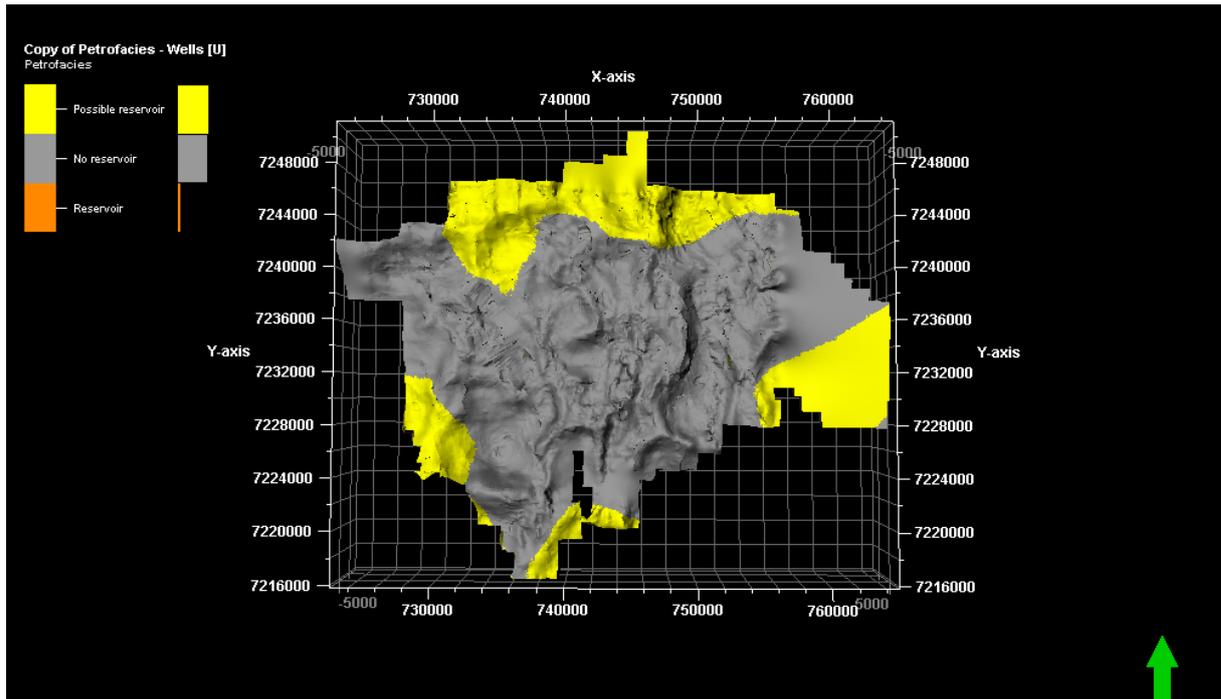


Figura 73. Vista aérea geral da propagação de petrofácies UM por meio de geoestatística.

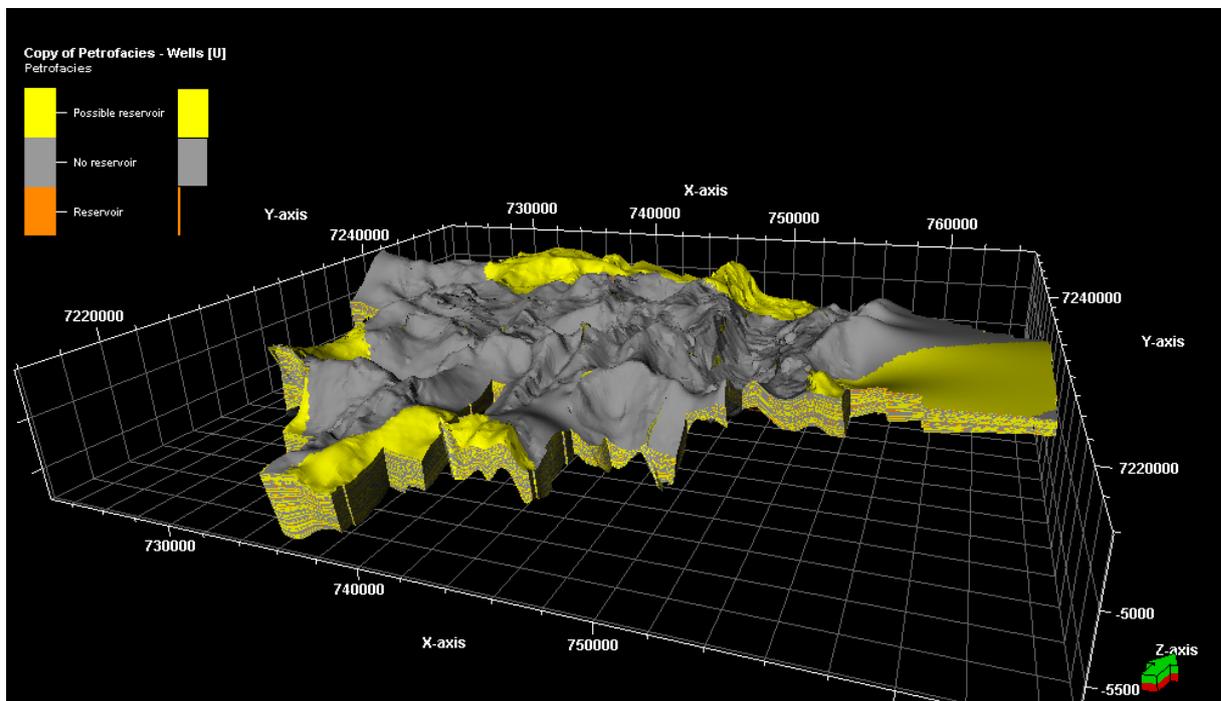


Figura 74. Vista lateral geral da propagação de petrofácies UM por meio de geoestatística.

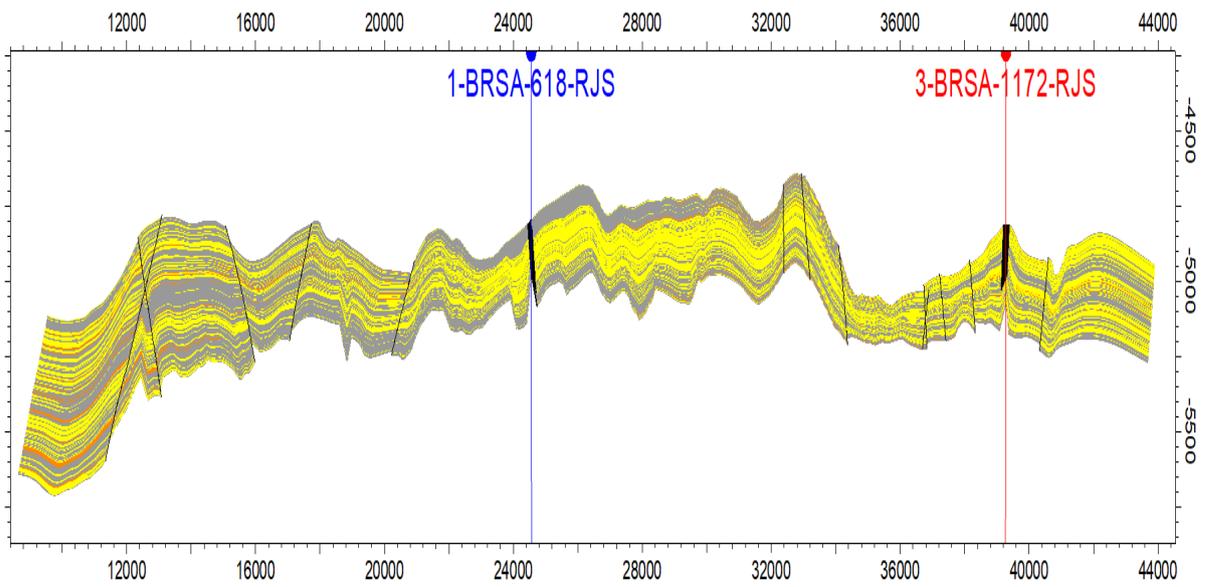


Figura 75. Seção estratigráfica entre 2 poços da propagação de petrofácies por meio de geoestatística.

7. Discussões

7.1. Modelos petrofísicos e interpretação de lâminas delgadas

A Tabela 6 compara as propriedades dos reservatórios estimadas para a Formação Barra Velha considerando os oito poços estudados neste trabalho, nos campos de Berbigão, Sururu e Atapu. A média ponderada de: PHIT, PHIE, FF, Sw, KTIM, Vclay é apresentada e comparada as propriedades da Formação Barra Velha para o campo de Búzios (Castro *et al.*, 2019).

Tabela 6. Média ponderada das principais propriedades da Formação Barra Velha dos campos Berbigão, Sururu e Atapu comparados com o campo Búzios.

Propriedades	Fm. Barra Velha (Área de estudo)	Fm. Barra Velha (Búzios)
PHIT (m ³ /m ³)	0,12	0,11
PHIE (m ³ /m ³)	0,11	0,11
FF (m ³ /m ³)	0,08	0,09
Sw (v/v)	0,62	0,31
KTIM (mD)	189,44	163,95
Vclay	0,13	0,07

Comparando os valores dos campos Berbigão, Sururu e Atapu com os valores do campo Búzios é possível observar que os valores são muito próximos aos valores de porosidades totais (PHIT), porosidades efetivas (PHIE) e fluidos livres (FF). São considerados valores médios bons de porosidades para rochas carbonáticas, visto que a maioria dos reservatórios de carbonatos tem porosidades entre 5 e 15% (Ahr, 2008).

A média dos valores de saturação de água nos campos de Berbigão, Sururu e Atapu é o dobro da média dos valores obtidos para o campo de Búzios, mostrando que uma grande quantidade de água está vez abaixo do contato água-óleo (OWC). É possível observar que em alguns poços podem ser encontradas zonas de hidrocarbonetos abaixo do contato água-óleo, devido a existência de uma zona de transição (Crain, 2002). O valor de saturação do poço 3 é 0.9599, o qual aporta significativamente ao valor médio de saturação de água na área de estudo.

Da mesma forma o poço 6 que tem aproximadamente o 50% da formação Barra Velha preenchida por água.

Deve-se considerar segundo Tosca e Wright, 2015, a diagênese intensa e heterogênea dos depósitos de Pré-sal resultou em grandes variações verticais e laterais na qualidade (permeabilidade e porosidade) dos reservatórios, isto devido a percolação de fluidos. Embora as características deposicionais exerçam um controle significativo sobre os processos diagenéticos, a maior parte da porosidade que está presente atualmente nos reservatórios do Pré-sal é de origem secundária (De Ros, 2018; Oliveira *et al.*, 2018).

A partir da classificação qualitativa de Levorsen (1967) a média de permeabilidades obtidas na Formação Barra Velha são de boa qualidade (100 a 1000 mD). Segundo Castro *et al.*, 2019, nesse tipo de rochas as zonas de alta permeabilidade geralmente estão relacionadas a poros do tipo *vug* conectados. Ao analisar as lâminas delgadas disponíveis, algumas apresentam poros do tipo *vug* representativos (principalmente *Grainstone*), embora não sejam muitas lâminas delgadas com estas características possivelmente a quantidade de poros tipo *vug* presentes podem aumentar o valor médio das permeabilidades (Figuras 76 e 77).

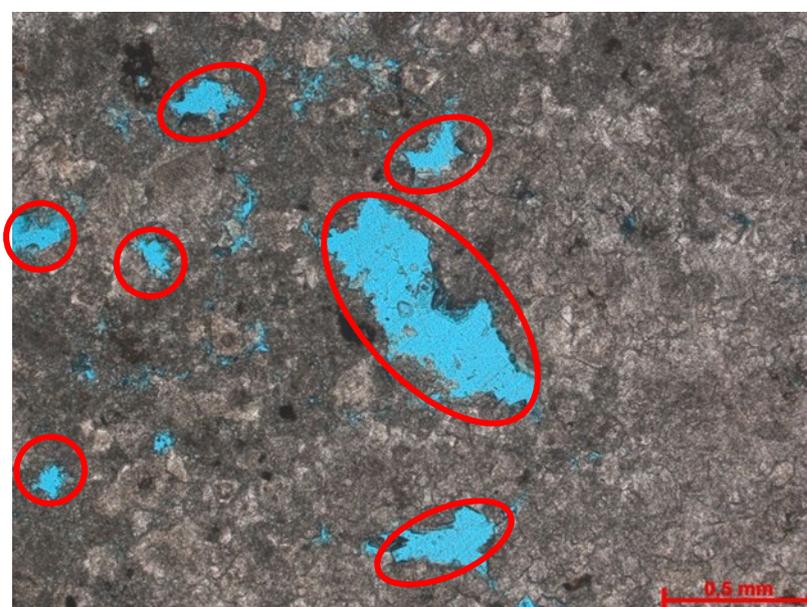


Figura 76. Lâmina delgada 1 de *Grainstone* apresentando poros tipo vug (círculos vermelhos).

Adicionalmente a dolomitização, silicificação, cimentação, dissolução e/ou recristalização foram promovidas em associação com fraturamento tectônico e hidráulico. É

possível interpretar que essas alterações possam estar relacionadas a processos ocorridos durante o soterramento e ao fluxo de fluidos hidrotermais. (Herlinger Jr. *et al.*, (2017), Poros *et al.*, (2017), e De Luca P. H. V. *et al.*, (2018)). A observação de feições de dolomitização e recristalização em lâminas delgadas na Figura 77, indica que a ocorrência de alterações mineralógicas na Formação Barra Velha nos campos de Berbigão, Sururu e Atapu.

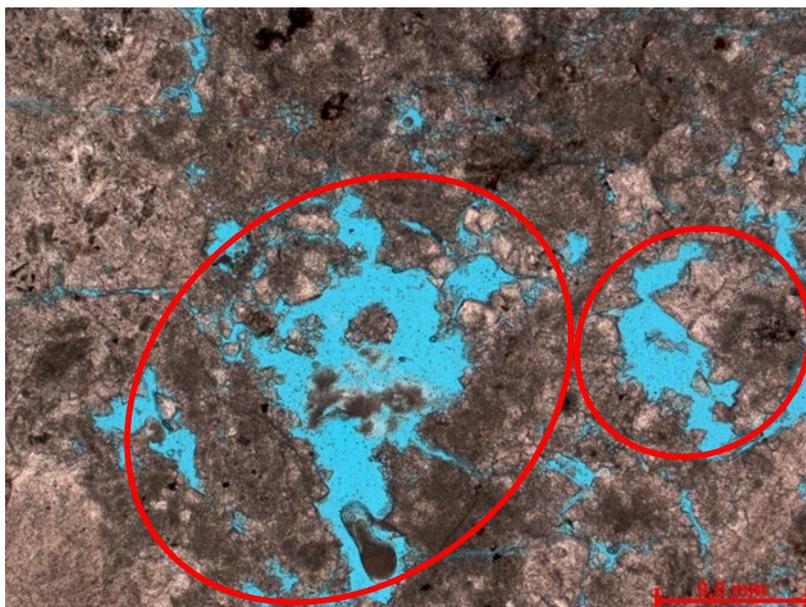


Figura 77. Lâmina delgada 2 de *Grainstone* apresentando poros tipo *vug* (círculos vermelhos).

O Vclay da Formação Barra Velha para os campos de Berbigão, Sururu e Atapu é quase o dobro do valor da mesma formação no campo de Búzios. Esses valores eram esperados, já que as respostas do GR eram altas em toda a Formação Barra Velha nos diferentes poços, apresentando respostas cada vez maiores em áreas próximas à Formação Itapema. Lembrando que o Vclay não registra a radioatividade natural das rochas e sim a porcentagem de rochas do tamanho de argilas.

7.2. Implementação de algoritmos de aprendizagem de máquina supervisionados e não supervisionados (*SVM Radial* e *K-Means Clustering*)

Torres *et al.*, (2020), implementou um algoritmo *SVM* em linguagem de programação *Jupyter Notebook* na Formação Itapema e na Formação Piçarras do campo de Gato do Mato na Bacia de Santos, obtendo como resultado no poço 1-SHEL-23-RJS uma taxa

de sucesso de 85,7%. Comparando os resultados, neste projeto foi implementado um *SVM* Radial obtendo um resultado de sucesso de 81,8%, dados de certeza muito próximos, confirmando que os *SVM* são uma boa técnica supervisionada para predição de fácies.

Na aplicação de algoritmo não supervisionado *K-Means Clustering* foram obtidas 3 petrofácies, mas Al-Mudhafar *et al.*, (2019), utilizou para caracterizar reservatórios carbonáticos no Iraque, duas metodologias entre essas *K-Means Partitioning* (Tan *et al.*, 2005), o qual é um algoritmo semelhante a *K-Means Clustering* só que a seleção de agrupamento acontece de outra forma, na classificação e predição de litofácies seus resultados foram comparados com descrições de testemunhos indicando uma grande semelhança. Os resultados de petrofácies neste projeto não foram comparados com descrições de testemunhos ou lâminas delgadas, mas sim com as unidades de fluxo, apresentado uma grande relação entre a petrofácies 1 e 3 (possível reservatório e reservatório) com a unidade de fluxo 4 (UF4) que apresenta as melhores propriedades petrofísicas para o fluxo.

É importante destacar que o Al-Mudhafar *et al.*, (2019), não determinou um limite de classificação para o algoritmo, ou seja, o algoritmo identificou quantas fácies considerou, obtendo 5 eletrofácies como resposta. Nesta pesquisa, este parâmetro foi de 3, número ótimo para poder levar os resultados ao modelo estrutural 3D. De acordo com Ferreira (2019), utilizou um agrupamento *K-Means Clustering*, obtendo como resultado 13 litofácies e finalmente identificando a mais representativa (6 das 13), porém há 2 considerações, primeiramente essas 13 litofácies apresentam muita variabilidade quando comparadas com as unidades de fluxo presentes, e a presença de um grande número de fácies dificulta a modelagem tanto estrutural quanto por meio de inversão sísmica, já que as variações de escala não permitiriam a observação das fácies na sísmica.

7.3. Identificação de unidades de fluxo

Segundo Rebelo *et al.*, (2022), se apresenta uma distribuição de fácies na Formação Barra Velha fornecida por Tucker e Wright, (1990, Figura 78). Observando a classificação apresentada na Figura 78 pode-se determinar que o agrupamento feito nesta pesquisa tem relações, onde *Spherulitestone*, *Grainstone* (união entre *Grainstone* e *Packstone*) e *Shrubstone* estão identificados em um ambiente deposicional litoral superior e inferior (*Upper & Lower Foreshore*) e os *Mudstone-Laminite* estão representados em um ambiente deposicional lago profundo (*Deep Lake*). Desta maneira, se pode relacionar que os comportamentos petrofísicos

entre *Spherulitestone*, *Grainstone* e *Shrubstone* serão semelhantes pelas características geológicas nas cercanias apresentadas durante sua deposição.

Rebello *et al.* (2022) apresentou unidades de fluxo semelhantes as obtidas nesta pesquisa, onde a unidade de fluxo 1 (UF1) representava as propriedades petrofísicas piores para o fluxo e a melhor unidade de fluxo, a unidade 4 (UF4) com as melhores propriedades petrofísicas para o fluxo. Rebello *et al.* (2022), apresentou como resultado que as fácies que estavam associadas a esta unidade de fluxo com boas características (UF4) vieram de um ambiente deposicional litoral superior e inferior, Figura 79.

FACIES ASSOCIATION	FACIES
Deep Lake	Mudstone (M)
Lower Shoreface	Muddy Spherulitestone (MSp) Spherulitic Mudstone (SpM)
Upper Shoreface	Shrubby spherulitestone with mud (ShSpM) Spherulitic shrubstone with mud (SpShM) Wackestone (W)
Lower Foreshore	Shrubby spherulitestone (ShSp) Spherulitic shrubstone (SpSh) Spherulitestone (Sp) Packstone (P)
Upper Foreshore	Grainstone/ Rudstone (G) Shrubstone (Sh)
Backshore	Weathering profile (WP)

Figura 78. Associações de fácies para a área de estudo definidas com base na interpretação. Na segunda coluna estão as fácies de cada associação e suas respectivas siglas (Rebello *et al.*, 2022).

Confirmando os resultados obtidos nesta pesquisa na Figura 55, a qual é um histograma da relação entre os valores de eletrofácies e unidades de fluxo. Portanto, os *Spherulitestone* e *Shrubstone* ao igual que para Rebello *et al.* (2022) estão altamente relacionados com a melhor unidade de fluxo (UF4) sendo uma fonte importante de fluxo para os reservatórios carbonáticos do Pré-sal.

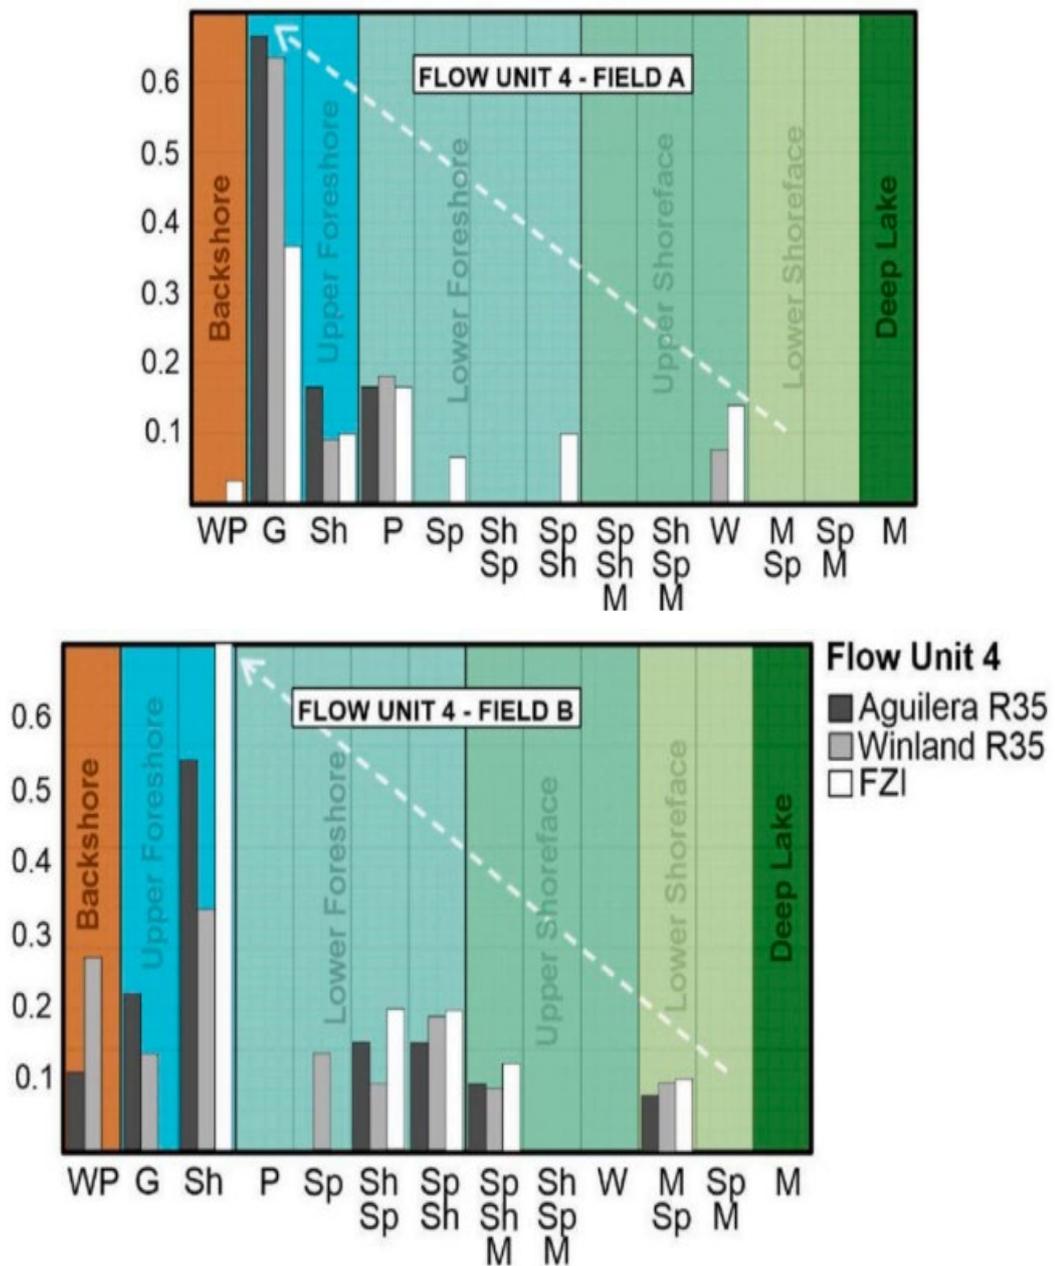


Figura 79. Histogramas mostrando a distribuição de fácies em cada unidade de fluxo (Rebelo *et al.*, 2022).

8. Conclusões

A determinação dos modelos petrofísicos de porosidades, saturações e permeabilidades da Formação Barra Velha nos 8 poços com informações disponíveis, permitiu ter uma visão multi-1D dos modelos petrofísicos e como eles se comportaram na área, apresentando características de fluxo das rochas no reservatório, dos fluidos contidos e das interações rocha-fluido presentes que se refletem nas unidades de fluxo. Dificuldades na interpretação de lâminas delgadas ocorreram devido às variações nos processos diagenéticos e alterações presentes nos processos de sedimentação das rochas, principalmente recristalizações e dolomitização, além das litofácies identificadas nas lâminas delgadas conforme o agrupamento apresentado por (Gomes *et al.*, 2020) não pertenciam a uma única litofácies.

A implementação do algoritmo de aprendizagem de máquina supervisionado (*SVM Radial*) deu uma certeza de 81,8%, o que é alto considerando as dificuldades de aprendizado de máquinas e a aplicação do algoritmo de aprendizagem de máquina não supervisionado (*K-Means Clustering*) determinou 3 petrofácies, a quantidade ideal para realizar um processo de up-scaling e não perder informações ao nível sub-sísmicas. A análise dos gráficos entre os perfis para determinar relações geofísicas apresentou a alta influência das variações e alterações nos processos sedimentológicos nas rochas carbonáticas da Formação Barra Velha, confirmando a dificuldade de aprendizagem da máquina para eletrofácies e uma melhor diferenciação de petrofácies.

Uma alta relação foi determinada entre a eletrofácies 2 e 3 (*Spherulitestone* e *Shrubstone*) e a unidade de fluxo 4 que possui as melhores propriedades petrofísicas para o fluxo, corroborando estudos semelhantes em campos próximos. Constatou-se que existe uma alta relação entre a petrofácies 1 e 3 (Possível reservatório e reservatório) com a unidade de fluxo 4, determinando que em geral que os 3 reservatórios na formação Barra Velha possuem características de escoamento muito boas.

Os modelos de falhas e horizontes interpretados mostram que quanto mais profunda for a interpretação no Pré-sal, mais ruído será apresentado na sísmica disponível, seguido dos resultados de interpretação de falhas e horizontes tendo implementados os filtros e atributos sísmicos (*DSMF*, *FEF*, *TFL*) mostram que os campos de Berbigão, Sururu e Atapu são altamente falhados, o que realmente levaria a pensar que estudos geomecânicos e tectônicos da área também deveriam ser considerados e, finalmente, tendo em conta o grande número de

falhas presentes, é quase impossível não pensar que existem falhas sub-sísmicas representativas que contribuem para a compreensão do comportamento estratigráfico e sedimentológicos dos reservatórios.

A criação do modelo estrutural da Formação Barra Velha nos campos de estudo e o posterior preenchimento ou população deste com as propriedades litológicas (eletrofácies) e petrofísicas (petrofácies) por meio de geoestatística, permitiu avaliar as variações laterais e verticais estudadas com pequenas malhas, permitindo assim observar a variabilidade das eletrofácies e petrofácies (anisotropia vertical) ao longo dos campos de Berbigão, Sururu e Atapu em uma vista 3D e poder comparar com seções sísmicas.

9. Referências

- AHR, W. M. 2008. Geology of Carbonate Reservoirs: The Identification, Description, and Characterization of Hydrocarbon Reservoirs in Carbonate Rocks. In Geology of Carbonate Reservoirs: The Identification, Description, and Characterization of Hydrocarbon Reservoirs in Carbonate Rocks. Doi: 10.1002/9780470370650.
- AL-MUDHAFAR, W. J., AL LAWE, E. M., NOSHI, C. I. Clustering analysis for improved characterization of carbonate reservoirs in a southern Iraqi oil field. Proceedings of the Annual Offshore Technology Conference, [s. l.], v. 2019-May, n. May, 2019.
- AMAEFULE J. O., ALTUNBAY M., TIAB D., KERSEY D. G., e KEELAN, D. K. 1993. Enhanced Reservoir Description: Using Core and Log Data to Identify Hydraulic (Flow) Units and Predict Permeability in Uncored Intervals/Wells, SPE 26436. In: SPE Annual Technical Conference and Exhibition, Houston, Texas, 3 – 6 Aug.
- AMARI, S. I., e WU, S. 1999. Improving *Support Vector Machine* classifiers by modifying Kernel functions. July 1999, (6), 783–789. Doi: 10.1016/S0893-6080(99)00032-5.
- AMYX, J. W., BASS D. M. JR, e WHITING, R. L. 1960. Petroleum reservoir engineering. McGraw-Hill, New York, 610 pp.
- ARAI, M. 2014. Aptian/Albian (Early Cretaceous) paleogeography of the South Atlantic: a paleontological perspective. Brazilian Journal of Geology, 44(2), 339-350. Doi: 10.5327/Z2317-4889201400020012.
- ARCHIE, G. E. 1952. Classification of carbonate reservoir rocks and petrophysical considerations. AAPG Bulletin 36, 2:278–298.
- ARNS, H., AVERDUNK, H., BAUGET, F., SAKELLARIOU, A., SENDEN, T., SHEPPARD, A., e KNACKSTEDT, M. 2004. Digital Core Laboratory: Reservoir Core Analysis From 3D Images. American Rock Mechanics Association.
- AZEVEDO, R. L. M. 2004. Paleocanografia e a evolução do Atlântico Sul no Albiano. Boletim de Geociências da Petrobras, 12(2), 231-249.
- BALDWIN, J. L., BATEMAN, R. M., e WHEATLEY, C. L. 1990. Application of a Neural Network to the Problem of Mineral Identification from Well Logs, The Log Analyst, 31(5), 279–293.

- BEUCHER, H., e RENARD, D. 2016. Truncated Gaussian and derived methods. *Compt. Rendus Geosci.* 348, 510–519. <https://doi.org/10.1016/j.crte.2015.10.004>
- BISBE, E. 2007. Curso básico de evaluación de formaciones para operadores de perforación y producción. Cuba, pp 16-19.
- BOSER, B. E., GUYON, I. M., e VAPNIK, V. N. 1992. A training algorithm for optimal margin classifiers. (pp. 144–152). Presented at the In Proceedings of the fifth annual workshop on Computational learning theory. <https://doi.org/10.1145/130385.130401>
- BUENO, G.V. 2004. Diacronismo de eventos no rifte Sul-Atlântico. *Boletim de Geociências da Petrobras*, 12(2), 203-229.
- CABRERA M. L., e ROJAS D. M. 2019. Caracterización petrofísica de yacimientos implementando atributos e inversión sísmica. Junio 2019, 1–118. <https://doi.org/10.18273/revbol.v42n3-2020004>
- CARRASQUILLA, A., SILVAB, J., e FLEXA, R. 2008. Associating Fuzzy Logic, Neural Networks and Multivariable Statistic Methodologies in the Automatic Identification of Oil Reservoir Lithologies Through Well Logs, *Revista de Geologia*, 21(1), 27–34.
- CASTRO, T. M., e LUPINACCI, W. M. 2019. Comparison between conventional and NMR approaches for formation evaluation of presalt interval in the Buzios Field, Santos Basin, Brazil. *Journal of Petroleum Science and Engineering*, 208(PD), 109679. <https://doi.org/10.1016/j.petrol.2021.109679>
- CHANG, H. K.; ASSINE, M. L.; CORRÊA, F. S.; TINEN, J. S.; VIDAL, A. C.; KOIKE, L. Sistemas petrolíferos e modelos de acumulação de hidrocarbonetos na Bacia de Santos. *Revista Brasileira de Geociências*, [s. l.], v. 38, n. 2, p. 29–46, 2008.
- CORTES, C., e VAPNIK, V. 1995. Support-vector networks. September 1995, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- CRAIN, E. R. 2002. Crain’s petrophysical handbook. Spectrum 2000 Mindware Ltd., Alberta, Canada.
- DE LUCA, P. H. V., MATIAS, H., CARBALLO, J., SINEVA, D., PIMENTEL, G. A., TRITLLA, J., ESTEBAN, M., LOMA, R., ALONSO, J. L. A., JIMÉNEZ, R. P., PONTET, M., MARTINEZ, P. B., e VEGA, V. 2017. Breaking barriers and paradigms in presalt exploration: The pão de açúcar discovery (Offshore Brazil). *AAPG Memoir*, 113, 177–193. <https://doi.org/10.1306/13572007M1133686>

- DE ROS, L. 2018. Genesis and Evolution of Aptian Pre-salt Carbonate Reservoirs in Southeastern Brazilian Margin. In: Brazilian Petroleum Conference, 2018, Rio de Janeiro. Anals. Rio de Janeiro, 2018. p. 1-43.
- DIAS, J. L. 2008. Estratigrafia e sedimentação dos evaporitos neo-aptianos na margem leste brasileira. In: W.U. Mohriak, P. Szatmari, S. Anjos (Orgs.). Sal: Geologia e Tectónica. Exemplos nas Bacias Brasileiras (pp. 223-231). São Paulo: Beca Edições.
- DIAS-BRITO, D. 1995. The South Atlantic Albian carbonates: their organogenic content and paleogeographic significance. I Workshop sobre paleoceanografia com ênfase em micropaleontologia e estratigrafia. Gramado, Brasil.
- DÍAZ, M. A. Estadística Aplicada. [s. l.], p. 1–167, 2002.
- DOVETON, J. 1994. Geologic log analysis using computer methods. Am. Assoc. Petroleum Geologists, Computer Methods in Geology, n. 2, 169 p.
- DU, Z., e MACGREGOR, L. 2010. Reservoir characterization from joint inversion of marine CSEM and seismic AVAdata using Genetic Algorithms: a case study based on the Luva gas field, EAGE Extended Abstract 2010; DOI:10.1190/1.3513888.
- DU, Z., TOPHAM, A., LOFTS, J. C., e SESHIA, A. A. 2020. Brazil pre-salt, santos basin: Feasibility study for the application ofborehole gravity to improve reservoir monitoring. Proceedings of the Annual Offshore Technology Conference, 2020-May. <https://doi.org/10.4043/30626-ms>
- DUNHAM, R. J. 1962. Classification of carbonate rocks according to depositional texture. In: In: HAM, W.E. (Ed.), Classification of Carbonate Rocks, vol. 1. American Association of Petroleum Geologists, Memoir, Tulsa, pp. 108–122.
- ELLIS, D. e SINGER, J. 2007. Well logging for earth scien-tists: Springer.
- FERREIRA, D. J. A., LUPINACCI, W. M., DE ANDRADE NEVES, I., ZAMBRINI, J. P. R., FERRARI, A. L., GAMBOA, L. A. P., e AZUL, M. O. 2019. Unsupervised seismic facies classification applied to a presalt carbonate reservoir, Santos Basin, offshore Brazil. *AAPG Bulletin*, 103(4), 997–1012. <https://doi.org/10.1306/10261818055>
- FERREIRA, D. J., LUPINACCI, W. M., NEVES, I. A., RODRIGUES, J. P., FERRARI, A. L., PIERANTONI, L. A., AZUL, M. O. 2019. Unsupervised seismic facies classification applied to a presalt carbonate reservoir, Santos Basin, offshore Brazil. *AAPG Bulletin* 2019; 103 (4): 997–1012. doi: <https://doi.org/10.1306/10261818055>
- FOLK, R. L. 1959. Practical petrographic classification of limestones. *Bull. Am. Assoc. Pet. Geol.* 43 (1), 1–38.

- GAMBOA, L. A. P., MACHADO, M. A. P., SILVEIRA, D. P., FREITAS, J. T. R., e SILVA, S. R. P. 2008. Evaporitos estratificados no Atlântico Sul. In: W.U. Mohriak , P. Szatmari , S. Anjos (Orgs.). Sal: Geologia e Tectónica. Exemplos nas Bacias Brasileiras (pp. 91-163). São Paulo: Beca Edições.
- GARCIA, S. F. M. 2012. Restauração estrutural da halotectônica na porção central da Bacia de Santos e implicações para os sistemas petrolíferos. Tese de Doutorado, Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, Brasil.
- GERSZTENKORN A., e MARFURT, K. J. 1999. Cálculos de coherencia basados en la estructura propia como una ayuda para el mapeo estratigráfico y estructural en 3D, *GEOPHYSICS* 64: 1468-1479. <https://doi.org/10.1190/1.1444651>
- GOMES, J. P., BUNEVICH, R. B., TEDESCHI, L. R., TUCKER, M. E., e WHITAKER, F. F. 2020. Facies classification and patterns of lacustrine carbonate deposition of the Barra Velha Formation, Santos Basin, Brazilian Pre-salt. *Marine and Petroleum Geology*, 113(December 2019), 104176. <https://doi.org/10.1016/j.marpetgeo.2019.104176>
- GUNTER, G. W.; FINNERAN, J. M.; HARTMANN, D. J.; e MILLER, J. D. Early determination of reservoir flow units using an integrated petrophysical method. *Proceedings - SPE Annual Technical Conference and Exhibition*, [s. l.], v. Omega, n. Pt 1, p. 373–380, 1997.
- HERLINGER, R., ZAMBONATO, E. E., e DE ROS, L. F. 2017. Influence of diagenesis on the quality of lower cretaceous pre-salt lacustrine carbonate reservoirs from northern Campos Basin, Offshore Brazil. *Journal of Sedimentary Research*, 87(12), 1285–1313. <https://doi.org/10.2110/jsr.2017.70>.
- INSUA, T. L., HAMEL, L., MORAN, K., ANDERSON, L. M., e WEBSTER, J. M. 2015. Advanced Classification Of Carbonate Sediments Based on Physical Properties, *Sedimentology*, 62(2), 590–606. DOI: 10.1111/sed.12168.
- IZBICKI, R., e DOS SANTOS, T. M. *Aprendizado de máquina: uma abordagem estatística*. Rafael Izbicki, 2020.
- JAGLAN, H., QAYYUM, F., e HÉLÈNE, H. Unconventional seismic attributes for fracture characterization. *First Break*, [s. l.], v. 33, n. 3, p. 101–109, 2015.
- JAMES, G., WITTEN, D., HASTIE, T.; TIBSHIRANI, R. *Springer Texts in Statistics An Introduction to Statistical Learning with application in R*. [S. l.: s. n.] 2013.
- KABACOFF, R. I. *Data analysis and graphics with R - bonus chapter 23*. [S. l.: s. n.] 2011.

- KABACOFF, R. R in *Action* (2nd ed.) (2015), Shelter Island, NY: Manning Publications Co.
- KOZENY, J. (1927). Ueber kapillare Leitung des Wassers im Boden. *Sitzungsber Akad. Wiss.* 136: 271-306.
- LEVORSEN, A. 1967. *Geology of Petroleum*. New York: WHFreeman e Co Ltd.
- LUCIA, F., KERANS, C., e JENNINGS, J. 2003. Carbonate Reservoir Characterization. In *Journal of Petroleum Technology* (Vol. 55, Issue 6). <https://doi.org/10.2118/82071-ms>.
- MADRUCCI, V., ARAÚJO, C. C., ANJOS, C. W. D., e SPADINI, A. R. 2019. Depositional paleoenvironment of authigenic magnesium clays in pre-salt of Santos Basin – Brazil. In: 16th International Meeting of Carbonate Sedimentologists, Bathurst Meeting Mallorca, pp. 152.
- MILANI, E. J., RANGEL, H. D., BUENO, G. V., STICA, J. M., WINTER, W. R., CAIXETA J. M., e NETO O. C. P. 2007. Bacias sedimentares brasileiras: cartas estratigráficas. *Boletim de Geociências da Petrobrás*, 15(1), 1-572.
- MOHRIAK, W. U. 2003. Bacias Sedimentares da Margem Continental Brasileira. In: L.A. Bizzi, C. Schobbenhaus, R. M. Vidotti, J. H. Gonçalves (eds.). *Geologia, Tectónica e Recursos Minerais do Brasil* (pp. 87-165). Serviço Geológico do Brasil - CPRM
- MOHRIAK, W. U. 2012. Bacias de Santos, Campos e Espírito Santo. In: Y. Hasui, C.D.R. Carneiro, F.F.M. Almeida, A. Bartorelli (Orgs.). *Geologia do Brasil* (pp. 481-496). São Paulo: Beca Edições .
- MOHRIAK, W. U., e SZATMARI, P. 2001. Salt tectonics and sedimentation along Atlantic margins: insights from seismic interpretation and physical models. *Geological Societ Of America Memoirs*, 193, p. 131-151.
- MONARD, M. C.; BARANAUSKAS, J. A. (2005). Conceitos sobre Aprendizado de Máquina, in *Sistemas Inteligêntes: Fundamentos e Aplicações*. Ed. Manole Ltda, Baueri, Cap. 4, pp. 89 – 114.
- MORAIS, J. M. 2013. *Petróleo em águas profundas: uma história tecnológica da Petrobras na exploração e produção offshore*. Brasília: IPEA, Petrobras, 424p.
- MOREIRA, J. L. P., MADEIRA, C. V., GIL, J. A., e MACHADO, M. A. P. 2007. Bacia de Santos. *Boletim de Geociências da Petrobras*, 15(2), 531-549.
- NORTH, F. K. 1985 . *Petroleum Geology* . Allen e Unwin , London , 607 pp.
- OLIVEIRA, D. M. ; PARK, A.; De Ros, L. F. 2018. Modeling the Genesis of Aptian Pre-Salt Deposits in Brazilian Basins. In: 2018 AAPG International Conference and

- Exhibition, 2018, Cape Town, South Africa. Abstracts Volume. Tulsa, Oklahoma, USA: American Association of Petroleum Geologists.
- PEÇANHA, A. A., LUPINACCI, W. M., FERREIRA, D. J. A., FREIRE, A. F. M. 2019. A workflow for reservoir characterization applied to presalt coquinas from the Linguado Field, Campos Basin, Brazil. *J. Petrol. Sci. Eng.* 183, 106451. <https://doi.org/10.1016/j.petrol.2019.106451>
 - PENNA, R.; LUPINACCI, M. W. 3D modelling of flow units and petrophysical properties in brazilian presalt carbonate. *Marine and Petroleum Geology*, [s. l.], v. 124, n. November 2020, p. 104829, 2021. Disponível em: <https://doi.org/10.1016/j.marpetgeo.2020.104829>
 - POROS, Z., JAGNIECKI, E., LUCZAJ, J., KENTER, J., GAL, B., CORREA, T. S., FERREIRA, E., KATHLEEN, A., ELIFRITZ, A., HEUMANN, M., JOHNSTON, M., e MATT, V. 2017. Origin of Silica in Pre-Salt Carbonates, Kwanza Basin , Angola. AAPG Annual Conference and Exhibition, 51413(May), 2–3. <https://doi.org/10.13140/RG.2.2.31863.42405>
 - QUIJANO, E. A., e VARCACEL, E. 2015. Interpretacion de registros geofisicos de pozo, pozo a, b y c. cuenca de los llanos orientales. 3(7), 59–78.
 - REBELO, T. B., BATEZELLI, A., MATTOS, N. H. S., LEITE, E. P. Flow units in complex carbonate reservoirs: A study case of the Brazilian pre-salt. *Marine and Petroleum Geology*, [s. l.], v. 140, n. July 2021, p. 105639, 2022. Disponível em: <https://doi.org/10.1016/j.marpetgeo.2022.105639>
 - RICCOMINI, C., SANT ANNA, L. G., e TASSINARI, C. C. G. 2012. Pré-sal: geologia e exploração. *Revista USP*, 95, 33-42. doi: 10.11606/issn.2316-9036.v0i95p33-42.
 - RODRIGUES, B. S. D. O. 2015. Interpretação Básica De Perfis Geofisicos De Poços Utilizando Linguagem Fortran 95 E *Softwares* Livres. 1–63.
 - RUSSELL, S.; NORVING, P. (2004). *Inteligência Artificial*. Editora Campus, 2º ed., Cap. 1, pp. 1 - 31.
 - SAMMUT, C. e WEBB, G. I. (Eds.). (2011). *Enciclopedia de aprendizaje automático* . Springer Science e Business Média.
 - SCHLUMBERGER, Log Interpretation, vol. II-Applications, New York. (1974).
 - SCHLUMBERGER. 1987. Log interpretation: Principles / Ap-plications. Schlumberger Ltd., New York, 198 p.
 - SERRA, O., e ABBOTT, H. 1982. The contribution of logging data to sedimentology and stratigraphy. *Society of Petro-leum Engineers Journal*, 5, 6, 29.

- SOUZA, I. A. 2008. Falhas de transferência da porção norte da Bacia de Santos interpretadas a partir de dados sísmicos: sua influência na evolução e deformação da bacia. Tese de Doutorado, Instituto de Geociências e Ciências Exatas. Universidade Estadual Paulista, Câmpus de Rio Claro.
- SOUZA, R. S., ARIENTI, L. M., VIANA, S. M., FALCAO, L. C., CUGLIERI, M. A., SILVA, R. P., LEITE, C. O., OLIVEIRA, V. C., OLIVEIRA, D. M., ANJOS, C., AMORA, R., CARMO, I. D., COELHO, C. E. 2018. Petrology of the hydrothermal and evaporitic continental Cretaceous (Aptian) presalt carbonates and associated rocks, South Atlantic Santos basin, offshore Brazil. In: AAPG/ACE Annual Convention e Exhibition, Salt Lake City, USA.
- TAN, P., STEINBACH, M., e KUMAR, V. 2005. *Cluster Analysis: Basic Concepts and Algorithms*. In: Introduction to Data Mining, Addison-Wesley, Boston.
- TANG, H., e WHITE, C. D. 2008. Multivariate Statistical Log–Log-Facies Classification on a Shallow Marine Reservoir, Journal of Petroleum Science and Engineering, 61(2), 88–93. DOI: 10.1016/j.petrol.2008.05.004.
- TIMUR. 1972. Nuclear magnetic resonance study of carbonate rocks The Log Analyst 13(5) pp 3-11.
- TORRES, A. L. P., e BATEZELLI, A. 2020. Applying supervised machine learning model to classify Eletrofácies in a Brazilian Pre-salt wellbore. Rio Oil and Gas Expo and Conference, 20(2020), 14–15. <https://doi.org/10.48072/2525-7579.rog.2020.014>
- TOSCANI, J. e WRIGHT V. P. 2015. Diagenetic pathways linked to labile Mg-clays in lacustrine carbonate reservoirs: a model for the origin of secondary porosity in the Cretaceous pre-salt Barra Velha Formation, offshore Brazil. Geological Society, London, Special Publication 435, p 33–46.
- TUCKER, M.E., WRIGHT, V.P. 1990. Carbonate Sedimentology. Blackwell Science Ltd., Oxford, p. 496p.
- VAPNIK, V. 1998. The Support Vector Method of Function Estimation. In Nonlinear Modeling (pp. 55–85). Boston, MA: Springer. Retrieved from https://link.springer.com/chapter/10.1007/978-1-4615-5703-6_3
- VERONA, P., CRISTINA, I., e GARCÍA, A. 2016. Una revisión sobre aprendizaje no supervisado de métricas de distancia. Revista Cubana de Ciencias Informáticas, 10(4), 43–67.
- VIANA, R. P. C. 2018. Impactos da halocinese na interpretação sísmica em uma porção distal da bacia de santos. June. <https://doi.org/10.13140/RG.2.2.22347.44325>

- VIDAL, A. C., KIANG, C. H., CORREA, F. S., FERNANDES, F. L., DE CASTRO, J. C., TINEN, J. S., KOIKE, L., M. L. A. e S. P. R. Interpretação e Mapeamento dos Sistemas Petrolíferos da Bacia de Santos. Anp/Unesp/Lebac, [s. l.], 2003.
- WIYOGA, S. A., XU, J., CAROLINA, A. D., e DEWANDA, R. 2021. Application of Class-Based Machine Learning for Potential Hydrocarbon Zones Identification: A Case Study. <https://doi.org/10.2118/205617-ms>

10. Anexos

Tabela 7. Valores típicos da Equação de Archie.

Variável	Valores de uso...	Condicionante
n	2.0 Porosidade de Archie. 1.8 (ou menos) para rochas de matriz argilosa. 4.0 Para rochas molhadas por óleo.	-
R_w	Valor calculado do registrador SP. Catálogos R_w estimados medidos a partir de amostra de água.	Incerteza no cálculo de a a partir do SP por espessura da formação.
\emptyset	Valores de testemunhos os perfis de densidade, densidade-neutrão ou sônico.	Configuração da matriz do perfil não coincide com a matriz da formação.
m	2.0 para porosidade de Archie. 1.7-2.0 para areias argilosas. 2.0-2.5 para porosidade tipo “ <i>Vug</i> ”. 2.5-3.3 para porosidade moldica (não conectada). ~1.0 para rochas fraturadas.	Não se tem seguridade no tipo de rocha ou geometrias de poro.
R_t	Valor calculado com perfis resistivos profundos (RILD ou RLLD).	Se existem <i>Washouts</i> .