

Estimativa de fácies no reservatório carbonático albio usando modelos de machine learning

Mohammad Saad Allahham*, A. Abel G. Carrasquilla*

*Laboratório de Engenharia e Exploração de Petróleo, Universidade Estadual do Norte Fluminense Darcy Ribeiro, Rodovia Amaral Peixoto, Km 163, Av. Brennand - Imboassica, Macaé - RJ, 27930-480.
(saadallahham@lenep.uenf.br), (abel@lenep.uenf.br).

Copyright 2022, SBGf - Sociedade Brasileira de Geofísica

Este texto foi preparado para a apresentação no IX Simpósio Brasileiro de Geofísica, Curitiba, 04 a 06 de outubro de 2022. Seu conteúdo foi revisado pelo Comitê Técnico do IX SimBGf, mas não necessariamente representa a opinião da SBGf ou de seus associados. É proibida a reprodução total ou parcial deste material para propósitos comerciais sem prévia autorização da SBGf.

Resumo

Este trabalho é um estudo das fácies dos carbonatos albianos de águas rasas da formação quissamã que correspondem a importantes reservatórios da bacia de Campos, utilizando dados de seis poços em campo. As fácies foram estudadas e coletadas de poços e diagnosticadas quanto ao conteúdo granular em quatro seções: 1) Grainstones, 2) Grainstones/Packstones, 3) Wackstones/Packstones e 4) Não Reservatório (Mudstone). Aplicando os modelos ML para estimar as fácies para os demais poços em campo usando o conjunto de dados de perfilação petrofísica: Raios gama (GR), Nêutrons (NPHI), Densidade (RHOB), e Sônico (DT), correspondentes a fácies.

Introdução

O presente estudo avaliou a confiabilidade do uso de modelos de aprendizado de máquina em uma estratégia de correlação quantitativa entre perfis convencionais e parâmetros de fácies. Algoritmos de Machine learning baseados em Análise Discriminante, Árvores de Decisão, Naive Bayes, Vizinho Mais Próximo, Máquina de Vetor de Suporte e Classificadores de Conjuntos, foram usados para estimar as fácies de três poços. A metodologia foi aplicada em quatro poços na Bacia de Campos, um poço foi utilizado para o aprendizado e validação dos sistemas algorítmicos, e os três poços foram utilizados para avaliar a extrapolação do aprendizado. No entanto, cada sistema atingiu aproximações significativas do parâmetro fácies, comprovando a utilidade e confiabilidade dos modelos de aprendizado de máquina na indústria do petróleo. Muitos estudos têm sido realizados sobre a formação albio no Brasil, principalmente nos reservatórios de petróleo de Campos, por ser considerada um reservatório de petróleo economicamente importante como reserva e produção de petróleo.

A importância das fácies em rochas carbonáticas e sua relação com processos morfológicos e ambientes deposicionais e seu impacto nas propriedades do reservatório. Este trabalho apresentará a localização do campo e informações geológicas sobre o reservatório estudado. Além disso, os dados estão disponíveis para

treinamento em técnicas de Machine Learning. O conjunto de dados de perfis de poços e a classificação de fácies serão apresentados. Os dados serão analisados por meio de diagramas, em seguida os resultados serão discutidos.

Características Geológicas

A Bacia de Campos está localizada no litoral norte do estado do Rio de Janeiro e sul do estado do Espírito Santo, limitada ao sul pelo Arco de Cabo Frio e ao norte pelo Arco da Vitória, possui mais de 1.600 poços perfurados em uma área de aproximadamente 100.000 km², ao longo de mais de três décadas de exploração de petróleo. A Bacia é classificada, segundo a Teoria das Placas Tectônicas, como margem passiva ou margem divergente. Trata-se de uma bacia na costa leste do Brasil, bacias desse tipo estão relacionadas ao rompimento do supercontinente Gondwana e a posterior evolução do Oceano Atlântico (DIAS et al., 1990).

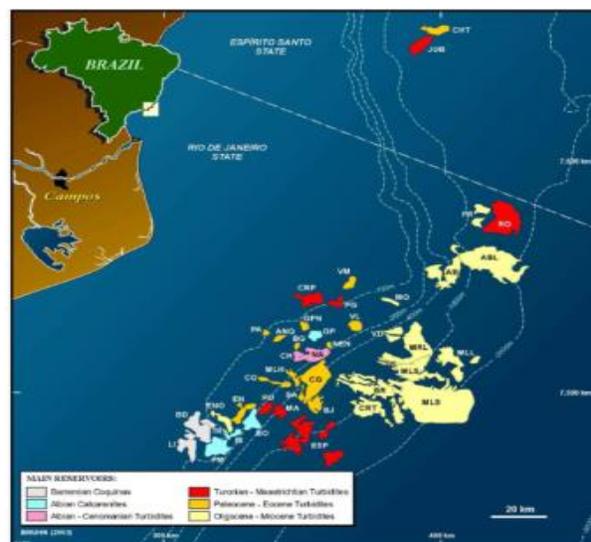


Figura 1. Localização da Bacia de Campos com os campos exploratórios (BRUHN et al., 2003).

Os carbonatos estão nas camadas do pré-sal, identificamos as coquinas da Formação Coqueiros, e após a deposição do sal temos os carbonatos albianos na Formação Quissamã, derivados de bancos oncolíticos/oolíticos e os calcirruditas do Membro Siri, derivado de um banco de algas vermelhas. Os campos

estudados estão localizados nas profundezas da água de aproximadamente 100m. Os reservatórios são geocronologicamente do período Cretáceo, idade Albiano, natureza de sedimentação marinha transgressiva e ambiente deposicional de plataforma rasa.

Dados e Metodologia

Este estudo foi baseado na classificação de Dunham para descrever e nomear fácies, que se preocupa principalmente com a matriz e grão das rochas. As fácies foram divididas, com base em Dunham, em quatro fácies principais: Grainstone, Packstone, Grainstone, Wackestone Packstone e Mudstone. Analisando as fácies para os poços de estudo de campo, percebemos que o poço 2 é o melhor poço para treinamento conforme mostrado na Tabela 2. As quatro fácies são adequadas para que os modelos de treinamento de aprendizado de máquina funcionem perfeitamente, com 22,48% para Mudstone, 25,12% para Wackestone/Packstone, 32,89% para Grainstone/Packstones e 19,50% para Grainstone, com observação total quantidade de 1210 e espessura de 242 m, em conclusão, é a que melhor se ajusta aos valores para o processo de treinamento.

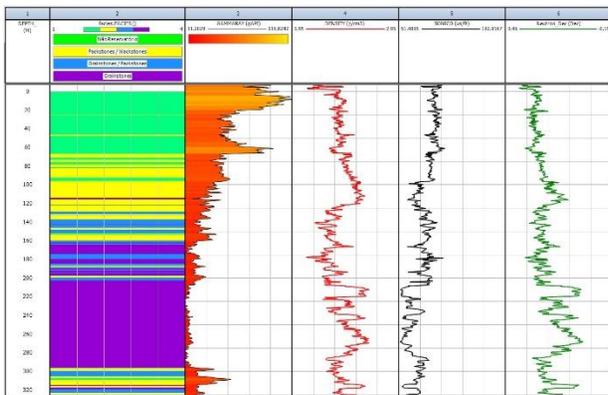


Figura 2. Os dados de perfil de poço disponíveis para o primeiro poço correspondem a fácies.

O estudo foi feito usando modelos de treinamento de aprendizado de máquina supervisionado usando os dados dos perfis de poços que compreendem de registro de Raios gama (GR), Densidade (RHOB), Sônico (DT) e Nêutron (NPHI) e medições de fácies estão disponíveis para três poços. A primeira etapa do trabalho foi analisar os dados fornecidos, analisar os perfis convencionais realizadas para identificar a região das fácies, e também, analisar os tipos das fácies através da análise de dados geofísicos. Os dados obtidos podem ser divididos em dados de aprendizado e dados de teste para verificar a precisão do modelo gerado. Fornecer séries de dados de registro de poços de entrada para prever o parâmetro de fácies; Além de fornecer a precisão das previsões durante o treinamento do algoritmo; assim que o

algoritmo terminar de aprender, aplicaremos o modelo a novos outros poços para prever as fácies.

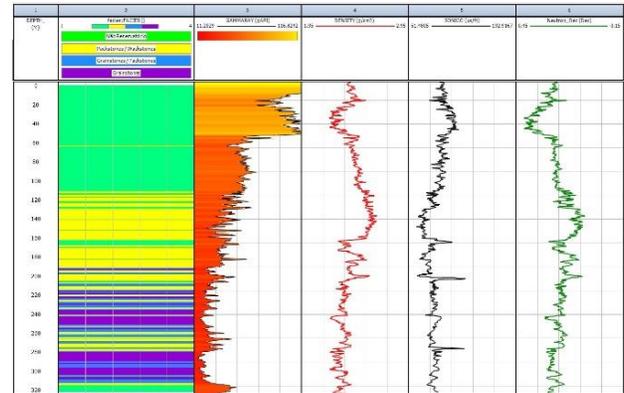


Figura 3. Os dados de perfil de poço disponíveis para o terceiro poço correspondem a fácies.

As Figuras 2 e 3 mostram os perfis convencionais variam ao longo do poço. Nesta etapa, os perfis utilizados neste estudo serão apresentados na seguinte ordem: Coluna 1: Profundidade (m); Coluna 2: Fácies (a área verde é mudstone (lamito), a área amarela é packstone/wackestone, a área azul é grainstones/packstone e a área roxa é grainstone); Coluna 3: Raios Gama ($^{\circ}$ API); Coluna 4: Densidade (g/cm^3); Coluna 5: Sônico (nos/pés); e Coluna 6: Nêutron (Dez).

Resultados

Os resultados foram gerados utilizando os softwares Matlab e Interactive Petrophysics (IP), fornecidos por suas empresas na forma de licença acadêmica, as figuras 5 e 6 mostram os melhores resultados de fácies obtidos a partir dos modelos de aprendizado de máquina e aplicados em cada poço.

• Primeiro poço

A Figura 5 mostra as fácies estimadas dos melhores modelos de 8 ML para poço_01 e como as fácies variam ao longo do poço. É possível identificar uma sequência de fácies no raso e aprofundamento do primeiro poço, de 0 a 70 m, há lamito na área verde, com uma camada muito pequena de packstone/wackestone na área amarela, de 70 m a 130 m, há packstone/wackestone na zona amarela com uma mistura de pequenas camadas de lamito e grainstone na zona amarela e violeta, então, há uma fácies de uma mistura de grainstone/packstone até 160m, depois, há um grainstone fácies com uma mistura muito pequena de camadas de grainstone/packstone até 300m. No aprofundamento, teremos uma textura com uma mistura de fácies de pequenas camadas com cerca de 20m de espessura, associadas à energia de formação.

Os resultados dos modelos ML apresentam valores elevados, mostrando todas as regiões de fácies, da mesma forma, a combinação dos resultados dos modelos ML mostra um cruzamento típico de regiões de fácies estimadas com regiões de fácies originais. Entre profundidades de 40 m a 60 m, 80 m a 120 m, 300 a 320 m, os modelos ML possuem alta capacidade de estimar a pequena camada de todos os tipos de fácies.

Os melhores resultados de fácies estimadas pelos modelos ML mostrando na figura 5 serão apresentados na seguinte ordem: Coluna 1: Profundidade (m); Coluna 2: Fácies (original); Coluna 3: Fácies (boostedtrees); Coluna 4: Fácies (rusboostedtrees); Coluna 5: Fácies (fine_tree); Coluna 6: Fácies (linear_svm); Coluna 7: Fácies (medium_tree); Coluna 8: Fácies (bagged_trees); Coluna 9: Fácies (coars_tree); e Coluna 10: Fácies (coars_gaussian).

• Terceiro poço

Analisando a Figura 6, podemos observar um excelente ajuste entre as fácies do poço e as fácies estimadas dos melhores modelos de 8 ML. Na profundidade de 0 m a 110 m, é possível identificar a presença de lamitos, na profundidade de 110 m a 210 m, é possível identificar a presença de packstone/wackestone com mistura de lamitos, e mistura ou fácies em pequenas camadas a uma profundidade de 210 m a 320 m.

Notamos que na profundidade de 60 m a 80 m a presença de uma pequena camada de packstone/wackestone, e na profundidade de 110 m a 320 m a presença de uma pequena camada de lamito, packstone/wackestone, grainstone/packstone e grão. Os modelos ML mostram uma alta capacidade de estimar essas pequenas liras de mistura de fácies, representando um típico cruzamento dos resultados das regiões de fácies estimadas com as regiões de fácies originais.

Os melhores resultados de fácies estimadas pelos modelos ML mostrando na figura 6 serão apresentados na seguinte ordem: Coluna 1: Profundidade (m); Coluna 2: Fácies (original); Coluna 3: Fácies (boostedtrees); Coluna 4: Fácies (fine_tree); Coluna 5: Fácies (rusboostedtrees); Coluna 6: Fácies (medium_tree); Coluna 7: Fácies (linear_svm); Coluna 8: fácies (kernel_Naïve_Bayes); Coluna 9: Fácies (medium_gaussian); e Coluna 10: Fácies (coars_tree).

Análise os resultados

A precisão no conjunto de dados de teste cresce quando o r-quadrado é alto, como nos modelos: árvores de decisão, Kernal naive Bayes, SVM linear, árvores impulsionadas, árvores ensacadas e árvores rusboosted, e diminui com a diminuição do r-quadrado como no restante dos modelos. Portanto, serão escolhidos os melhores modelos de acurácia e r-quadrado, e assim ter um bom resultado para as fácies. Sabendo que o uso de modelos com baixo r-quadrado e acurácia terá resultados ruins. Com a avaliação do r-quadrado para cada modelo,

na tabela 1, mostrando que os 3 melhores modelos para prever fácies para o poço 1 são: boosted trees, rusboost trees e fine_tree, e para o poço 3 são: boostedtrees, fine_tree e rusboostedtrees.

Tabela 1. Os melhores modelos de ML para estimar fácies de acordo com o r-quadrado para cada modelo.

Rank	Poço_01	R ²	Poço_03	R ²
1	boostedtrees	0.961	boostedtrees	0.954
2	rusboostedtrees	0.958	fine_tree	0.953
3	fine_tree	0.957	rusboostedtrees	0.952
4	linear_svm	0.946	medium_tree	0.946
5	medium_tree	0.945	linear_svm	0.928
6	bagged_trees	0.937	kernel_Naïve_Bayes	0.924
7	coars_tree	0.933	medium_gaussian	0.917
8	coars_gaussian	0.913	coars_tree	0.916

A avaliação final será calculada considerando o valor de r quadrado de cada modelo. Os mesmos conjuntos de dados de teste (perfis) são os mesmos conjuntos dos dados usados de todos os poços. Quando cada poço tem o conjunto de variação dos dados de fácies, o mesmo poço tem seus valores de variação logarítmica, então a partir do ranking dos resultados, a diferença aparecerá. Podemos ver através da figura 4, na linha azul, a evolução da precisão no conjunto de dados de treinamento e teste de cada modelo de ML. Também observamos um aumento na acurácia no conjunto de treinamento, que tem relação de proporção direta com o r-quadrado dos modelos ML.

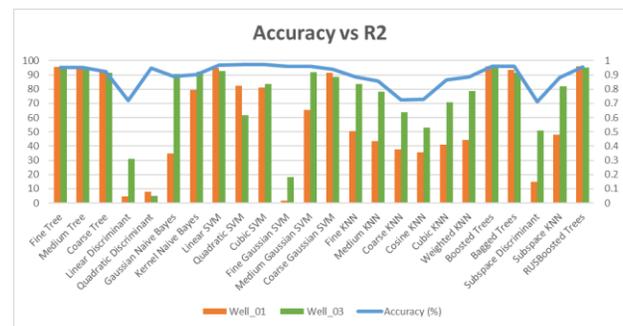


Figura 4. Variação do parâmetro r-quadrado versus avaliação de acurácia de todos os modelos de ML.

Discussão e Conclusões

O conjunto de dados disponível tem uma grande diferença no número e tipos de amostras de fácies para cada poço, o problema que foi apresentado neste trabalho é o fato de aplicar esses dados a sistemas de ML preditivos, pois isso objetiva a aplicação de métodos supervisionados em um ambiente típico. Problema da

indústria do petróleo que é a previsão de fácies e, portanto, de um reservatório.

O problema de previsão de fácies é um grande desafio para a indústria do petróleo, pois não é totalmente dominado por especialistas e, se não estiver bem estruturado em um reservatório, acaba afetando sua exploração. A dificuldade em obter melhores resultados está relacionada à baixa qualidade dos dados, que são obtidos em condições adversas, e não estão diretamente relacionados à forma como as classes foram definidas, e outro problema é a quantidade de dados disponíveis.

Diferentes geólogos geraram diferentes classificações de fácies rochosas para o campo aplicado deste estudo. Como resultado deste estudo, não foi observada grande variação nos resultados das fácies entre os diferentes métodos testados. Tendo obtido precisão semelhante e resultados de fácies previstos. Assim, neste trabalho, foram estudadas as respostas de métodos de aprendizado de máquina para predição de fácies. Considerando as limitações inerentes ao problema, ou seja, falta de homogeneidade entre os dados dos poços, os resultados obtidos foram considerados satisfatórios e as melhorias geradas pelos diferentes modelos podem ser comprovadas.

Agradecimentos

Agradecemos à UENF/LENEP pela infraestrutura, CNPq pela bolsa de pesquisa, LR Senergy pela licença do software IP, MathWorks pela licença do software MATLAB e Petrobras/ANP pelo conjunto de dados e recursos de pesquisa.

Referências

Alexsandro, G. C., da P. Carlos, A. C., and Geraldo, G. N., 2017, Facies classification in well logs of the Namorado oilfield using Support Vector Machine algorithm, 15th International Congress of the Brazilian Geophysical Society & EXPOGEF, Rio de Janeiro, Brazil, 31 July-3 August 2017, 1853–1858.

Bestagini, P., Lipari, V., and Tubaro, S., 2017, A machine learning approach to facies classification using well logs, SEG Technical Program Expanded Abstracts, 2137–2142.

Byrnes, A. P., DuBois, M. K., Carr, T. R., Magnuson, M., 2001, Western Tight Gas Carbonates: Comparison of Council Grove Group, Panoma Field, Southwest Kansas and Western Low Permeability Sandstones.

Breiman, L., Friedman, J., Stone, J. C., Olshen, R. A., 1984, Classification and Regression Trees, ed. Taylor & Francis, ISBN: 0412048418, 9780412048418.

Bruhn, C.; Gomes, J.; Lucchese, C. & Johann, P. 2003. Campos basin: reservoir characterization and manage-

ment - historical overview and future challenges. Offshore Technology Conference. Paper OTC 15220.

DIAS, J.; SCARTON, J.; ESTEVES, F.; CARMINATTI, M.; GUARDADO, L. Aspectos da evolução tectono-sedimentar e a ocorrência de hidrocarbonetos na bacia de campos. Origem e evolução de bacias sedimentares. Rio de Janeiro: Petróleo Brasileiro SA, p. 333–360, 1990.

Dubois, M. K., G. C. Bohling, and S. Chakrabarti, 2005, Comparison of four approaches to a rock facies classification problem: Computers & Geosciences, 33, no. 5, 599–617, <http://dx.doi.org/10.1016/j.ageo.2006.08.011>.

Guardo, M., 2018, Facies classification with features engineering, clustering, and gradient boosting trees: CREWES (University of Calgary) Research Report — Volume 30.

Guozhu, D., G., Huan, L., 2018, Feature Engineering for Machine Learning and Data Analytics, Chapman & Hall/CRC data mining and knowledge discovery series.

Hall, B., 2016, Facies classification using machine learning: The Leading Edge, 35, No. 10, 906–909.

Hossin, M., Sulaiman, M.N., 2015, a Review on Evolution Metrics for Data Classification Valuations, International Journal of Data Mining & Knowledge Management Process (IJDMP) Vol.5, No.2.

Silva, A., Neto, I. L., Carrasquilla, A., Misságia, R., Ceia, M., and Archilha, N., 2014, Neural network computing for lithology prediction of carbonate-siliciclastic rocks using elastic, mineralogical and petrographic properties, 13th International Congress of the Brazilian Geophysical Society & EXPOGEF, Rio de Janeiro, Brazil, 26–29 August 2013, 1055–1058.

Smith, T., 2018, What is the “Holy Grail” of Machine Learning in Seismic Interpretation ?, Geophysics Society of Houston. VanderPlas, J., 2016, Python Data Science Handbook: Essential Tools for Working with Data: O’reilly, first edition.

Tabela 2. Distribuição e divisão das fácies dos poços estudados.

No. fácies	Poço 01			Poço 02			Poço 03		
	Quantia	%	Espessura (m)	Quantia	%	Espessura (m)	Quantia	%	Espessura (m)
1.Mudstone	382	23.51%	76.4	272	22.48%	54.4	686	42.22%	137.2
2.Wackstone / Packstone	427	26.28%	85.4	304	25.12%	60.8	513	31.57%	102.6
3.Grainstone / Packstone	218	13.42%	43.6	398	32.89%	79.6	215	13.23%	43
4.Grainstone	598	36.80%	119.6	236	19.50%	47.2	211	12.98%	42.2
SUM	1625	100.00%	325	1210	100.00%	242	1625	100.00%	325

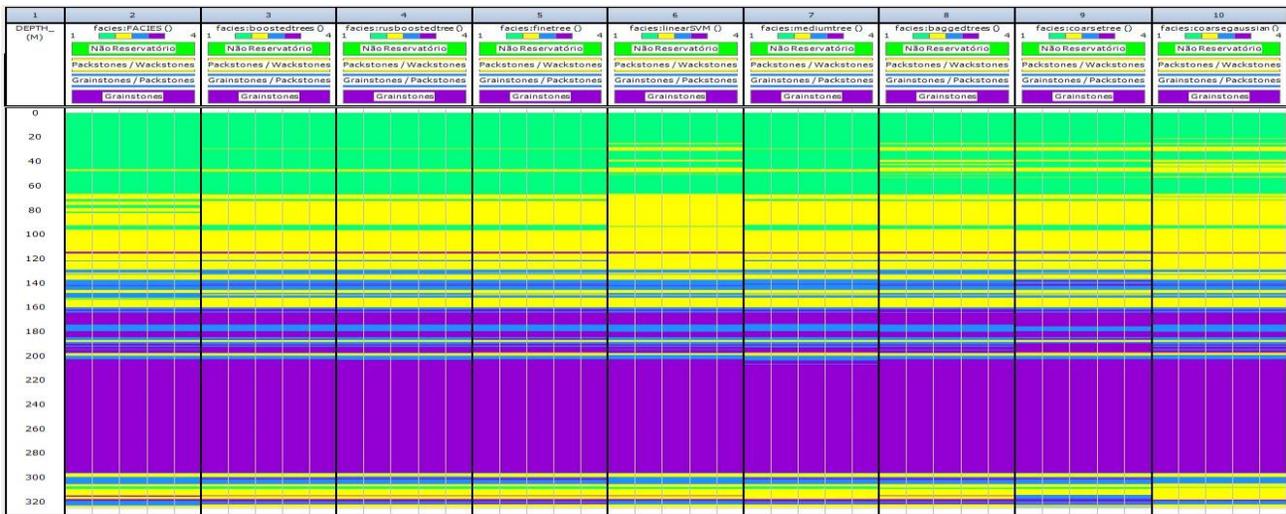


Figura 5. Os resultados de fácies estimados para o poço_01.

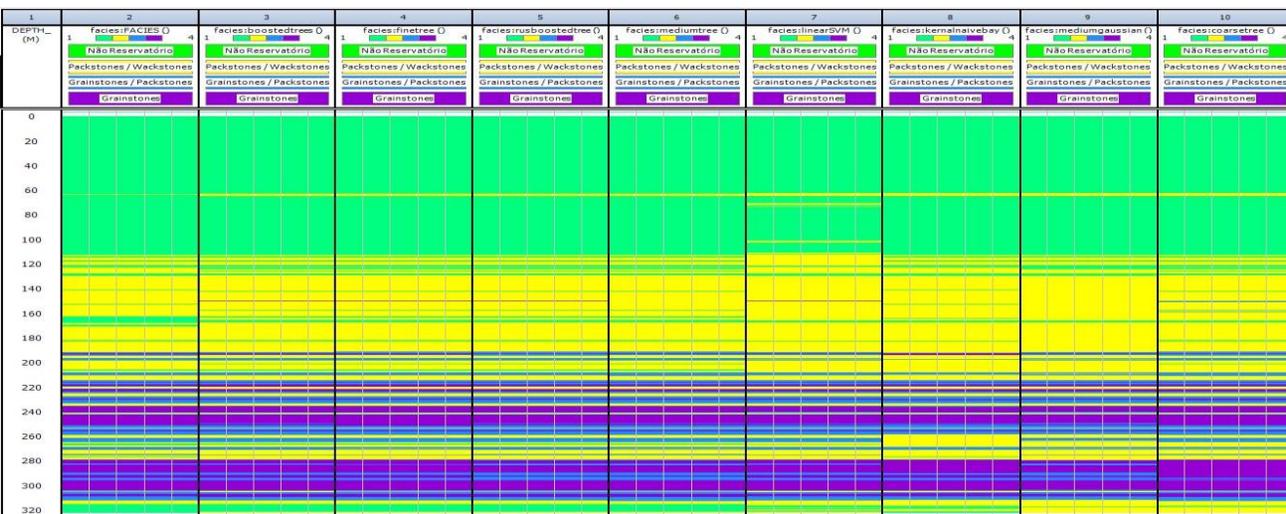


Figura 6. Os resultados de fácies estimados para o poço_03.