

# APLICAÇÃO DE APRENDIZADO DE MÁQUINA EM DADOS GEOSTATÍSTICOS DE PERFIS GEOFÍSICOS PARA IDENTIFICAÇÃO DE CAMADAS ROCHOSAS COM FLUIDOS

*Data de aceite: 02/06/2023*

**Livia Evelin De Souza Auzier**

Universidade Federal do Amazonas

**Joemes de Lima Simas**

Universidade Federal do Amazonas

data analysis and understanding reservoir geology.

**KEYWORDS:** Machine Learning, Geostatistics, Fluid Identification, Rock Layers.

**ABSTRACT:** The oil industry uses advanced tools to process large volumes of data and identify complex patterns. Machine learning stands out in this context, offering efficient solutions to this demand. This work is under development and presents partial results of data obtained from wells for geostatistical manipulation and machine learning. The project is based on numerical methods to collect and interpret information from geophysical profiles, such as gamma ray, spontaneous potential, gauge, among others. Each fluid (oil, water and gas) presents unique characteristics in these profiles, enabling its identification. The algorithm that will be developed will analyze and interpret data from geophysical profiles, learning to identify patterns and classify different types of fluids, allowing for more efficient and safe exploration of petroleum resources. The project also aims to contribute to undergraduate teaching in Petroleum Engineering and Geology, providing students with a modern tool for

## 1. INTRODUÇÃO

Os perfis geofísicos são técnicas geofísicas com o objetivo de identificar as propriedades físicas a partir de medições e registro da subsuperfície ao longo do poço perfurado, deles são obtidos os dados necessários e relevantes na técnica de aprendizado de máquina.

Segundo Coppin (2010), o aprendizado está diretamente ligado com a inteligência, pois realmente se um sistema é capaz de aprender a exercer determinada tarefa mereça então ser chamado de inteligente. Embora possam ser confundidos muitas vezes como sinônimos, Machine Learning e Inteligência Artificial não são a mesma coisa. Na verdade, a IA é o campo mais amplo, enquanto o Aprendizado de Máquina é uma subcategoria específica da IA que se concentra na capacidade de aprender com dados (Handtalk,2024).

De acordo com a *Statistical Analysis System* (SAS, 2019), o Machine Learning é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana.

Na técnica de *machine learning* considera-se o aprendizado indutivo que pode ser dividido em supervisionado e não-supervisionado.

No aprendizado supervisionado é fornecido ao algoritmo de aprendizado, ou indutor, um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido. No aprendizado não-supervisionado o indutor analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira, formando agrupamentos ou *clusters* (Cheeseman & Stutz 1990).

Dessa forma um algoritmo é uma sequência de instruções ou regras que um computador segue para executar uma determinada tarefa e quando o algoritmo se inspira no funcionamento do cérebro, sendo composto por camadas de neurônios que aprendem padrões e informações mais complexas é denominado de rede neural que é ideal para entender o que aparece em imagens e saber o que alguém está dizendo (Handtalk,2024).

Sendo assim, ao invés de programar regras específicas, os algoritmos de Machine Learning são alimentados com dados e aprendem a realizar tarefas sem serem explicitamente programados.

Para o desenvolvimento deste projeto será considerado o aprendizado não-supervisionado no qual tem como objetivo desenvolver um algoritmo que permite a análise de dados obtidos a partir de características fornecidas pelos perfis geofísicos para aplicar em metodologia de ensino para melhor compreensão dos alunos e conseqüentemente para a utilização no mercado de trabalho, trazendo resultados mais eficientes e robustas com relação a detecção de fluidos.

## 2 . OBJETIVOS

### 2.1 Objetivo Geral:

Desenvolver um algoritmo para implementação de aprendizado de máquinas buscando a identificação de fluido em camadas rochosas, com base em dados geoestatísticos.

### 2.2 Objetivos Específicos:

- Pesquisar a bibliografia referente ao aprendizado de máquina;
- Estudar a linguagem de programação escolhida;
- Analisar os dados geoestatisticamente do perfil geofísico;

- Estudar da linguagem de programação que irá ser utilizada;
- Elaborar o algoritmo para aprendizado;
- Iniciar o aprendizado no perfil geofísico;
- Analisar os dados obtidos;

### 3 . MATERIAIS E MÉTODOS

A primeira etapa é a pesquisa bibliográfica para um melhor entendimentos métodos numéricos a fim de que fosse possível o agrupamento de informações e a interpretação destas.

A segunda etapa é a coleta de dados de poços da Bacia do Solimões e da Bacia do Amazonas na Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) Terrestre <https://reate.cprm.gov.br/anp/TERRESTRE>. Poços da década de 80 foram selecionados.

Em seguida, após a análise dos dados de poços disponibilizados no site foram escolhidos os poços que apresentavam pelo menos 06 (seis) perfis distintos, sendo eles:

- Perfil de Raio Gama;
- Perfil de Calibre;
- Perfil de Potencial Espontâneo;
- Perfil de Densidade;
- Perfil Sônico;
- Perfil Neutrônico;

Com base nas informações individuais de cada poço, foram selecionados 2 poços:

- Um na Bacia do Solimões: Poço 3-RUC-20-AM, com área de estudo na profundidade de 2.550m a 2.750m.
- E outro na Bacia do Amazonas: Poço 1-LIT-1-AM, com área de estudo na profundidade de 2.450m a 2.550m.

A partir da escolha dos poços, foi coletado e estudado as informações de cada perfil do poço, para que assim esses dados sejam utilizados no *software* para o treinamento da máquina. Para a organização dos dados que serão manipulados para a análise geoestatística foram montadas duas tabelas contendo a profundidade; dados dos 06 (seis) perfis relacionados acima e os tipos de rochas. A partir da montagem das tabelas com os dados adquiridos dos poços as informações serão inseridas em um *software*.

A quinta etapa é o treinamento do algoritmo a partir dos dados dos perfis listados na terceira etapa.

## 4 . RESULTADOS E DISCUSSÕES

Apartir das coletas de dados foram coletados dados de 80 poços da Bacia do Solimões e da Bacia do Amazonas, 10 poços foram selecionados com base na disponibilidade dos seis perfis mencionados, então 2 poços foram selecionados para a análise final, um de cada bacia (Amazonas e Solimões). Para a análise dos dados de cada poço com os dados dos perfis (Perfil de Raio Gama, Perfil de Calibre, Perfil de Potencial Espontâneo, Perfil de Densidade, Perfil Sônico, Perfil Neutrônico) foi montada duas tabelas (1 e 2) referentes aos poços nas Bacias do Amazonas e Solimões respectivamente

**Tabela 1 - Dados geoestatísticos dos perfis da Bacia do Amazonas (Poço: 1-Lit-1-Am).**

DADOS GEOESTATÍSTICOS - BACIA DO AMAZONAS: POÇO 1-LIT-1-AM							
Prof. (2550 - 2750 M)	GR (0-150 API)	SP (50.0 - 150.0 Mv)	CALI (6.0 - 16.0 In)	DT (240.0 - 40.0 µs)	RHOB (2.0 - 3.0 g/cm <sup>3</sup> )	NPHI (0.4 - 2.0 pu)	Tipo de rocha
2450	30 API	60 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,16pu	FOLHELHO
2455	30 API	40 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,16pu	FOLHELHO
2460	30 API	70 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,28 pu	FOLHELHO
2465	30 API	60 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,16pu	FOLHELHO
2470	30 API	40 Mv	6 In	50 µs	0,08 g/cm <sup>3</sup>	2,28 pu	FOLHELHO
2475	30 API	60 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2480	15 API	40 Mv	6 In	40 µs	0,7 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2485	15 API	70 Mv	6 In	40 µs	0,08 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2490	15 API	40 Mv	6 In	50 µs	0,7 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2495	15 API	40 Mv	6 In	50 µs	0,65 g/cm <sup>3</sup>	1,92 pu	FOLHELHO
2500	45 API	40 Mv	6 In	50 µs	0,65 g/cm <sup>3</sup>	1,92 pu	FOLHELHO
2505	75 API	30 Mv	6 In	50 µs	0,65 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2510	15 API	40 Mv	6 In	40 µs	0,65 g/cm <sup>3</sup>	2,04 pu	FOLHELHO
2515	120 API	40 Mv	6 In	30 µs	0,65 g/cm <sup>3</sup>	1,44 pu	FOLHELHO
2520	135 API	30 Mv	6 In	40 µs	0,65 g/cm <sup>3</sup>	1,68 pu	FOLHELHO
2525	150 API	30 Mv	6 In	30 µs	0,65 g/cm <sup>3</sup>	1,56 pu	FOLHELHO
2530	30 API	30 Mv	6 In	20 µs	0,75 g/cm <sup>3</sup>	1,84 pu	ARENITO
2535	150 API	30 Mv	6 In	20 µs	0,55 g/cm <sup>3</sup>	0,96 pu	ARENITO/FOLHELHO
2540		30 Mv	6 In		0,55 g/cm <sup>3</sup>		ARENITO
2545		80 Mv	6 In		0,65 g/cm <sup>3</sup>		ARENITO
2550			6 In		0,6 g/cm <sup>3</sup>		ARENITO

Fonte: Agência nacional do Petróleo, Gás Natural e Biocombustíveis (ANP).

**Tabela 2 - Dados geoestatísticos dos perfis da Bacia do Solimões (Poço: 3-Ruc-20-Am).**

DADOS GEOESTATÍSTICOS - BACIA DO SOLIMÕES: POÇO 3-RUC-20-AM							
Prof. (2550 - 2750 M)	GR (0-150 API)	SP (58.0 - 313.0 Mv)	CALI (6.0 - 16.0 In)	DT (240.0 - 40.0 µs)	RHOB (2.0 - 3.0 g/cm <sup>3</sup> )	NPHI (45.0 - 15.0 pu)	Tipo de rocha
2550	60 API	109.0 Mv	9 IN	30 µs	0,35 g/cm <sup>3</sup>	36 pu	ARI NITO
2555	30 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	21 pu	ARENITO
2560	45 API	109.0 Mv	9 IN	40 µs	0,55 g/cm <sup>3</sup>	21 pu	ARENITO
2565	120 API	109.0 Mv	9 IN	40 µs	0,65 g/cm <sup>3</sup>	24 pu	ARGILITO
2570	45 API	109.0 Mv	10 IN	40 µs	0,35 g/cm <sup>3</sup>	33 pu	ARI NITO
2575	60 API	109.0 Mv	11 IN	30 µs	0,4 g/cm <sup>3</sup>	36 pu	ARENITO
2580	60 API	109.0 Mv	9 IN	30 µs	0,3 g/cm <sup>3</sup>	33 pu	ARENITO
2585	30 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	27 pu	ARENITO
2590	45 API	109.0 Mv	10 IN	30 µs	0,55 g/cm <sup>3</sup>	21 pu	ARI NITO
2595	45 API	109.0 Mv	11 IN	30 µs	0,55 g/cm <sup>3</sup>	24 pu	ARENITO
2600	45 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	21 pu	ARENITO
2605	45 API	109.0 Mv	9 IN	30 µs	0,5 g/cm <sup>3</sup>	30 pu	ARENITO
2610	30 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	21 pu	ARI NITO
2615	30 API	109.0 Mv	10 IN	20 µs	0,55 g/cm <sup>3</sup>	21 pu	ARENITO
2620	45 API	109.0 Mv	9 IN	30 µs	0,45 g/cm <sup>3</sup>	24 pu	ARENITO
2625	30 API	109.0 Mv	9 IN	20 µs	0,55 g/cm <sup>3</sup>	24 pu	ARENITO
2630	45 API	109.0 Mv	9 IN	40 µs	0,4 g/cm <sup>3</sup>	30 pu	ARI NITO
2635	45 API	109.0 Mv	9 IN	40 µs	0,4 g/cm <sup>3</sup>	33 pu	ARENITO
2640	60 API	109.0 Mv	10 IN	40 µs	0,4 g/cm <sup>3</sup>	33 pu	ARGILITO/ARENITO
2645	60 API	109.0 Mv	9 IN	20 µs	0,5 g/cm <sup>3</sup>	33 pu	ARGILITO
2650	30 API	109.0 Mv	10 IN	30 µs	0,55 g/cm <sup>3</sup>	24 pu	ARENITO
2655	45 API	109.0 Mv	9 IN	40 µs	0,45 g/cm <sup>3</sup>	27 pu	ARENITO
2660	150 API	109.0 Mv	10 IN	40 µs	0,6 g/cm <sup>3</sup>	36 pu	FOLHELO
2665	150 API	109.0 Mv	10 IN	40 µs	0,6 g/cm <sup>3</sup>	36 pu	DIAMICTITO
2670	135 API	109.0 Mv	10 IN	40 µs	0,7 g/cm <sup>3</sup>	33 pu	DIAMICTITO
2675	120 API	109.0 Mv	9 IN	40 µs	0,55 g/cm <sup>3</sup>	33 pu	FOLHELO
2680	120 API	109.0 Mv	9 IN	40 µs	0,65 g/cm <sup>3</sup>	30 pu	DIAMICTITO
2685	150 API	109.0 Mv	9 IN	70 µs	0,65 g/cm <sup>3</sup>	33 pu	ARENITO
2690	150 API	109.0 Mv	9 IN	60 µs	0,5 g/cm <sup>3</sup>	27 pu	ARENITO
2695	135 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	33 pu	FOLHELO
2700	75 API	109.0 Mv	9 IN	30 µs	0,35 g/cm <sup>3</sup>	33 pu	ARENITO
2705	75 API	109.0 Mv	9 IN	40 µs	0,35 g/cm <sup>3</sup>	36 pu	ARGILITO
2710	45 API	109.0 Mv	9 IN	30 µs	0,45 g/cm <sup>3</sup>	30 pu	ARENITO
2715	60 API	109.0 Mv	9 IN	30 µs	0,5 g/cm <sup>3</sup>	30 pu	ARENITO
2720	30 API	109.0 Mv	9 IN	30 µs	0,55 g/cm <sup>3</sup>	21 pu	ARENITO
2725	30 API	109.0 Mv	9 IN	30 µs	0,4 g/cm <sup>3</sup>	21 pu	ARENITO
2730	90 API	109.0 Mv	9 IN	30 µs	0,5 g/cm <sup>3</sup>	33 pu	ARENITO
2735	150 API	109.0 Mv	9 IN	30 µs	0,6 g/cm <sup>3</sup>	30 pu	ARENITO/ARGILITO
2740	135 API	109.0 Mv	12 IN	30 µs	0,6 g/cm <sup>3</sup>	30 pu	ARGILITO/ARENITO
2745	105 API	109.0 Mv	13 IN	20 µs	0,6 g/cm <sup>3</sup>	21 pu	ARENITO
2750	120 API	109.0 Mv	10 IN	40 µs	0,6 g/cm <sup>3</sup>	24 pu	ARGILITO/ARENITO

Fonte: Agência nacional do Petróleo, Gás Natural e Biocombustíveis (ANP).

A análise dos dados está em andamento para a próxima etapa que é o Treinamento da máquina onde os dados analisados serão utilizados para a criação do algoritmo e início do treinamento da máquina.

Os resultados parciais demonstram o potencial da metodologia proposta para a identificação de camadas rochosas com fluidos. Dessa forma para a conclusão do projeto o treinamento da máquina será primordial de modo que permita a validação do algoritmo, que serão fundamentais para avaliar a efetividade da ferramenta.

## 5 . CONCLUSÕES

A análise dos dados está em andamento para a próxima etapa que é o treinamento da máquina onde os dados analisados serão utilizados para a criação do algoritmo e início do treinamento. Os resultados parciais demonstram o potencial da metodologia proposta para a identificação de camadas rochosas com fluidos. Dessa forma para a conclusão do projeto o treinamento da máquina será primordial de modo que permita a validação do algoritmo, que serão fundamentais para avaliar a efetividade da ferramenta.

## 6 . REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, L. E. Aplicação De Visão Computacional Em Imagens Capturadas Por Drones Em Inspeção De Plataformas De Petróleo, 2019.

AMARAL, R. G. Implementação da técnica de machine learning (ml) para processamento de dados sísmicos. Rio Oil and Gas, 2020.

AMARAL, R. G. Elaboração de algoritmo para aplicação de aprendizado de máquina a fim de reconhecer armadilhas geológicas do tipo domo salino em seções sísmicas, TCC, 2021.

AMINZADEH, F.; DASGUPTA, S. Geofísica para Engenheiros de Petróleo. 1ª Edição. Editora Elsevier, 2015.

ANP (Agência Nacional do Petróleo, Gás Natural e Biocombustíveis). Disponível em: < <https://reate.cprm.gov.br/anp/TERRESTRE>>. 2023

COPPIN, Ben. Inteligência artificial. Rio de Janeiro: LTC, 2010.

GALA, Ana Sofia. Disponível em: <https://www.handtalk.me/br/blog/aprendizado-de-maquina/>). Acesso em: 28/04/2024.

MARSLAND, S. Machine Learning - An algorithmic perspective. 2. ed. Estados Unidos: CRC Press, 2015.

PROJECTSAL). Disponível em : <https://www.k2sistemas.com.br/trace/> 2023.

SBGf (Sociedade Brasileira de Geofísica) – Estimativa da porosidade usando ferramentas de aprendizagem de maquina nao parametrica. Disponível em:< [https://sbgf.org.br/mysbgf/eventos/expanded\\_abstracts/i/](https://sbgf.org.br/mysbgf/eventos/expanded_abstracts/i/)>.

## **7. AGRADECIMENTOS**

Meus agradecimentos ao Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação – PIBITI da UFAM pela concessão da bolsa que possibilitou o desenvolvimento do projeto e à professora Dra Joemes de Lima Simas que coordena o Laboratório de Petrofísica do curso de Engenharia de Petróleo onde a pesquisa foi realizada sob sua orientação.