



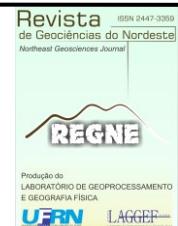
ISSN: 2447-3359

REVISTA DE GEOCIÊNCIAS DO NORDESTE

Northeast Geosciences Journal

v. 11, nº 2 (2025)

<https://doi.org/10.21680/2447-3359.2025v11n2ID39943>



AVALIAÇÃO DE REDES NEURAIS NA CARACTERIZAÇÃO DE RESERVATÓRIOS COM DADOS DE RMN: PREDIÇÃO DE PARÂMETROS FZI, RQI E HFU, E CLASSIFICAÇÃO DE TIPOS POROS

Maurício Gabriel Lacerda Mafra¹; Milton Morais Xavier Junior²

¹ UFRN, PPGG, Natal/RN, Brasil. Email: mauricio.mafra.103@ufrn.edu.br
ORCID: <https://orcid.org/0000-0003-2720-4655>

² UFRN, PPGG, Natal/RN, Brasil. Email: milton.morais@ufrn.br
ORCID: <https://orcid.org/0000-0002-9072-6475>

Resumo: O aprendizado de máquina tem impulsionado avanços científicos ao viabilizar a análise de grandes e complexos conjuntos de dados, mesmo entre variáveis não correlacionadas. Na caracterização de reservatórios, parâmetros petrofísicos como porosidade e permeabilidade são fundamentais para o cálculo de indicadores como o Flow Zone Indicator (FZI), Reservoir Quality Index (RQI) e Hydraulic Flow Units (HFU), e que podem auxiliar na classificação de tipos de poros. A Ressonância Magnética Nuclear (RMN) é uma técnica robusta nesse contexto, permitindo medições diretas de porosidade e estimativas de permeabilidade por meio de modelos. Neste estudo, dados de porosidade e permeabilidade a gás de 506 amostras de carbonatos foram utilizados para avaliar quatro modelos semiempíricos (SDR, Timur-Coates, Rios e Han) e um modelo de aprendizado profundo, o Perceptron Multicamadas (MLP). O MLP superou os modelos semiempíricos, com R^2 de 0,79 e $\sigma = 3,07$ para treinamento e 0,71 e $\sigma = 3,92$ para teste. O modelo também diferenciou eficientemente as HFUs e apresentou valores próximos aos obtidos em laboratório. Na classificação dos tipos de poros, o MLP apresentou desempenho superior. Assim, a integração de dados de RMN com modelos de aprendizado profundo aprimora significativamente a caracterização de HFU, FZI e RQI.

Palavras-chave: Redes Neurais; Permeabilidade; RMN

Abstract: Machine learning has advanced scientific research by enabling the analysis of large and complex datasets, including uncorrelated variables. In reservoir characterization, petrophysical parameters such as porosity and permeability are essential for calculating indicators like Flow Zone Indicator (FZI), Reservoir Quality Index (RQI), and Hydraulic Flow Units (HFU), and that can aid in pore type classification. Nuclear Magnetic Resonance (NMR) is a powerful technique in this context, as it enables direct porosity measurements and permeability estimation through models. In this study, porosity and gas permeability data from 506 carbonate samples were used to evaluate four semi-empirical models (SDR, Timur-Coates, Rios, and Han) and a deep learning model, the Multi-Layer Perceptron (MLP). The MLP outperformed the semi-empirical models, achieving an R^2 of 0.79 and $\sigma = 3.07$ for training and 0.71 and $\sigma = 3.92$ for testing. It also effectively differentiated HFUs and closely matched laboratory results. In pore type classification, the MLP model showed superior performance. These results highlight the potential of integrating NMR data with deep learning to improve HFU, FZI, and RQI predictions and support more accurate pore type characterization.

Keywords: Neural Network; Permeability; NMR

Recebido: 22/04/2025; Aceito: 23/06/2025; Publicado: 25/07/2025.

1. Introdução

A alta performance na exploração de reservatórios é fundamental em todas as fases, desde a identificação de zonas de interesse, até nas fases de modelagem, otimização da produção e planejamento de operações futuras (LUCIA *et al.*, 2003; TIAB e DONALDSON, 2016), o que em reservatórios com alta heterogeneidade pode levar a diversas complicações. Para obter essa alta performance é necessário obter uma boa caracterização, que em grande medida depende das modelagens petrofísicas, e que possui os parâmetros principais a porosidade (ϕ) e a permeabilidade (k) (CANNON, 2018). Com esses parâmetros de porosidade e permeabilidade é possível estimar novas informações que auxiliam na identificação de zonas de interesse em um reservatório, como: o *Reservoir Quality Index* (*RQI*) (1), a Porosidade Normalizada (ϕ_z) (2), os *Flow Zone Indicators* (*FZI*) (3) e as *Hydraulic Flow Units* (*HFU*) (AMAEFULE *et al.*, 1993; TIAB e DONALDSON, 2016, EFTEKHARI *et al.*, 2024). Em posse dessas identificações pode-se caracterizar também aos tipos de porosidade a partir do método que Soto *et al.* (2010) chamou coeficiente de transformação (r) (4) e o ângulo “*polar arm*” do valor *FZI* (θ_{Polar}) (5).

$$RQI = 0,0314 \cdot \left(\sqrt{\frac{k}{\phi}} \right) \quad (1)$$

$$\phi_z = \frac{\phi}{1 - \phi} \quad (2)$$

$$FZI = \frac{RQI}{\phi_z} \quad (3)$$

$$r = \phi_z \cdot \left(\sqrt{FZI^2 + 1} \right) \quad (4)$$

$$\theta_{Polar} = \tan^{-1}(FZI) \quad (5)$$

A obtenção da permeabilidade laboratorial não é viável em todo um reservatório, por isso se faz necessário a sua estimativa através de modelos. A técnica de Ressonância Magnética Nuclear (RMN) obtém não só a porosidade, mas também seus resultados podem ser usados para estimar a permeabilidade com modelos semiempíricos ou de aprendizado de máquina, configurando-se como uma ferramenta petrofísica avançada e robusta para aquisição informações essenciais na exploração de reservatórios (KENYON *et al.*, 1988; COATES *et al.*, 1999; DUNN, 2002; WEI *et al.*, 2024). Portanto, a comparação dos resultados de diferentes modelos de permeabilidade a partir dos dados de RMN e sua validação com dados laboratoriais torna-se um dos principais objetivos no entendimento e calibração de modelos de um reservatório (GAVIDIA *et al.*, 2024). Os modelos de aprendizado de máquina surgem como um auxiliador, pois não é em todos os casos que os resultados laboratoriais possuem correlação direta com os resultados estimados por modelos, o que pode levar a erros grosseiros quando esses resultados forem utilizados para caracterizações posteriores (GARIA *et al.*, 2022).

Portanto, este trabalho visa obter os dados laboratoriais de porosidade e permeabilidade a gás, de 506 amostras, de um ambiente com alta heterogeneidade a fim de comparar esses resultados com os da técnica de RMN. Serão utilizados diversos modelos semiempíricos e um modelo de aprendizado de máquina para verificar qual deles possui melhor aproximação com os dados laboratoriais. Esses dados serão também utilizados para obter informações relevantes das amostras, a fim de caracterizá-las e obter o *FZI* e *HFU*, podendo então avaliar como se comportam os resultados dos modelos quando são utilizados para as avaliações do reservatório.

1.1. Ressonância Magnética Nuclear

A RMN fornece dados como porosidade e distribuição de tempos de relaxação, relacionados às concentrações de spins e à estrutura do meio poroso. É uma técnica não destrutiva, aplicada em laboratório ou em poços, com plugs, testemunhos ou durante a perfuração. Baseia-se na relaxação dos spins nucleares do hidrogênio, presentes na água e hidrocarbonetos. O princípio de funcionamento acontece quando um campo magnético externo (B_0) faz os spins nucleares precessionarem, e um campo adicional (B_1) aplicado em ângulo induz um torque na precessão na direção de B_1 , gerando magnetizações (M_0 e M_1). A medição do tempo de relaxação transversal (T_2) usa pulsos específicos, como na sequência CPMG (CARR and PURCELL, 1954; MEIBOOM and GILL, 1958) e no eco de spin (HAHN, 1950).

A partir dessa relaxação é possível obter a curva de distribuição de tempos T_2 , que pode ser obtida através de métodos interativos como a Técnica de Reconstrução Interativa Simultânea (SIRT) (CHEN *et al.*, 2010). As distribuições dos tempos de relaxação são utilizadas para as modelagens da permeabilidade, pois são comumente interpretadas associadas aos tamanhos de poros (COATES *et al.*, 1999; HAN *et al.*, 2018). Os principais modelos para obter a permeabilidade utilizando RMN utilizam informações da curva de distribuição T_2 (KENYON *et al.*, 1988, COATES, 1999, RIOS *et al.*, 2011, HAN *et al.*, 2018).

1.2. Caracterização do Reservatório e dos Tipos de Poros

Com as informações de porosidade e permeabilidade se torna possível a caracterização do reservatório através do RQI , FZI e HFU . O RQI indica a qualidade de um reservatório de ser explorado, pois um local pode ter uma alta permeabilidade mas baixa porosidade, ou vice-versa, o que pode tornar o reservatório com uma baixa qualidade, porém, mesmo regiões com baixo RQI pode possuir zonas de fluxo hidráulico semelhantes a regiões com alto RQI , dependendo da sua porosidade normalizada, por isso se faz necessário a avaliação do FZI . Quando diferentes intervalos possuem FZI semelhantes caracteriza-se uma HFU . O agrupamento das HFU pode ser realizado arbitrariamente ou seguindo valores predeterminados ou ajustado a informações geológicas ou utilizando métodos de separação estatística.

Como demonstrado por Soto *et al.* (2010) as informações do r e θ_{Polar} pode ser usada para identificar os tipos de porosidade entre fraturas/vuggs de porosidade intercristalina por meio de uma função de corte sigmoidal (6).

$$S(r) = \frac{A + B}{\left\{1 + e^{-\left[\frac{(r-C)}{D}\right]}\right\}} \quad (6)$$

$A = -3,5916207, B = 5,06265818, C = -0,72243226$ e $D = 0,371324681$

1.3. Geologia

A região de estudo se encontra na Bacia Potiguar (Figure 1-A), que está localizada na margem equatorial brasileira, sendo formada por processos de rifteamento durante a formação do Oceano Atlântico no Jurássico-Cretáceo (MATOS, 1992; de CASTRO, 2012), com porções *onshore* e *offshore*. A Formação Jandaíra compreende uma plataforma carbonática formada entre os períodos Turoniano e Campaniano (CÓRDOBA, 2001). Essa região foi escolhida por possuir boa analogia aos reservatórios do pré-sal e estar aflorando, possibilitando o estudo das propriedades do espaço poroso com boa precisão e baixo custo. Ao todo foram utilizadas 506 amostras de plug coletadas de diferentes locais da Formação Jandaíra, onde há uma parte aflorante e outra que foi estudada por meio de testemunhos de poços (Figure 1-B). Essas localizações possuem alta carstificação e estruturas permoporosas com alta heterogeneidade (LOPES *et al.*, 2023; ARAUJO *et al.*, 2023), que também deve auxiliar na avaliação dos tipos de porosidade, e nas complexidades das previsões de permeabilidade e dos índices do reservatório FZI , RQI e HFU .

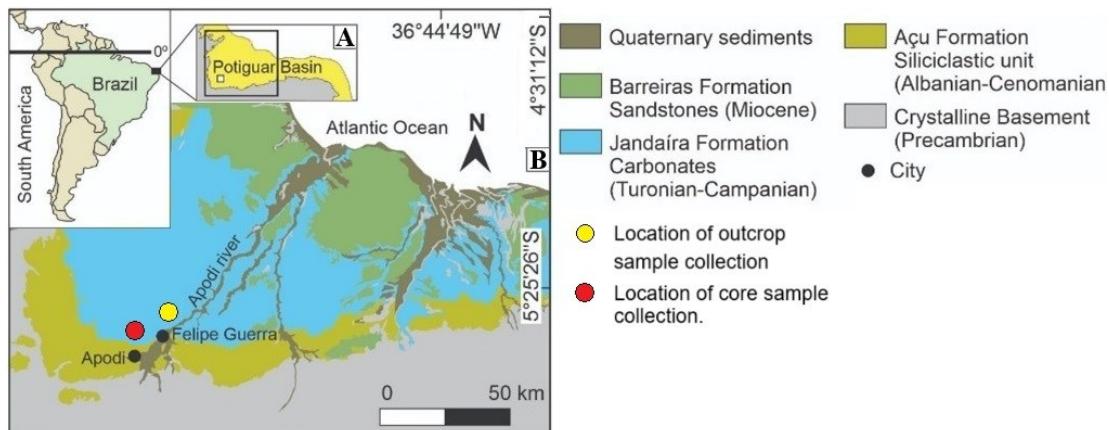


Figura 1 – A) Localização da Bacia Potiguar no Nordeste Brasileiro, B) Mapa regional da Bacia Potiguar.
Fonte: Autores (2025)

1.4. Revisão das Redes Neurais Artificiais

Algoritmos de aprendizado de máquina conseguem lidar com dados complexos e realizar previsões precisas, mesmo em contextos não-lineares. Nos modelos supervisionados, os dados possuem rótulos que orientam o ajuste dos parâmetros para minimizar os erros. Entre os modelos mais usados está a Rede Neural Artificial (RNA), especialmente a Rede de Perceptrons de Múltiplas Camadas (MLP) (GÉRON, 2021). O perceptron é a unidade fundamental das RNA, sendo, portanto, um modelo matemático feito por funções (w_{nm}) que alteram o dado de recebido de entrada (x_i) ou de outro perceptron a fim de serem ativados propagando a informação a fim de gerar um resultado esperado. A combinação de múltiplos perceptrons organizados e bias (b) em camadas permite que a rede transforme os dados de entradas em qualquer valor, que em problemas de regressão corresponde a uma estimativa única (Figura 2).

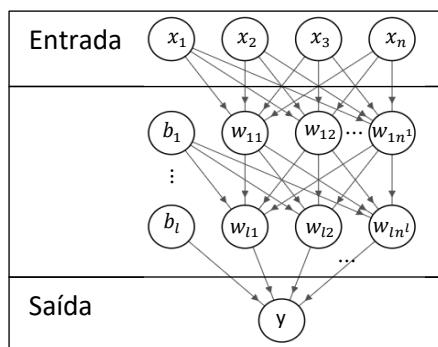


Figura 2 – A arquitetura de um modelo MLP inicia-se pela conexão dos dados de entrada com os perceptrons da primeira camada, e esse perceptrons se conectando com outros em profundidade, até que os dados de entrada tenham um resultado de saída.
Fonte: Autores (2025)

A arquitetura do modelo MLP define a estrutura com camadas, número de perceptrons e funções de ativação, influenciando como os dados são processados. O treinamento ajusta pesos e bias por retropropagação (HINTON *et al.*, 2006), ao longo de várias épocas, para minimizar o erro. A arquitetura envolve hiperparâmetros definidos pelo usuário, enquanto os parâmetros são ajustados automaticamente. Como não há regra exata para os melhores hiperparâmetros

(WOLPERT, 1996), é necessário testar várias configurações. O GridSearchCV, da Scikit-Learn (PEDREGOSA *et al.*, 2015), automatiza esse processo, testando combinações e aplicando validação cruzada.

1.5. Modelos Sempímpicos

Os modelos semiempíricos mais comuns para estimar a permeabilidade através dos dados de RMN são utilizados os modelos Schlumberger Doll-Research (SDR) (7) (KENYON *et al.*, 1988), o modelo Timur-Coates (8) (COATES *et al.*, 1999), o modelo proposto por Han *et al.* (2018) (9), e o modelo estatístico proposto por Rios *et al.* (2011). Os modelos são compostos por funções exponenciais, em que seus coeficientes são ajustados para os resultados de RMN de cada campo amostral através da obtenção da permeabilidade laboratorial, torna-se possível assim obter com certa precisão a permeabilidade de novas amostras obtendo apenas dados de RMN.

Os modelos convencionais, SDR, Timur-Coates e Han, determinam faixas ou valores da curva de distribuição T_2 para ajuste dos coeficientes exponenciais através de regressões lineares. O modelo SDR utiliza se utiliza apenas da porosidade de RMN ϕ_{RMN} e o valor do logaritmo médio da distribuição T_2 ($T_{2 lm}$) (10). O modelo Timur-Coates (COATES *et al.*, 1999) utiliza também a ϕ_{RMN} , mas se propõe a utilizar o *Bulk Volume Irreducible (BVI)* e o *Free Fluid Index (FFI)* (TIMUR, 1969) para avaliar as porções da curva de distribuição T_2 . O modelo Han (HAN *et al.*, 2018) também utiliza a ϕ_{RMN} mas utiliza frações de tamanhos de poros (S_1 , S_2 , S_3 e S_4), calibrados por Mercury Intrusion Capillary Pressure (MICP). Já o modelo estatístico se baseia na identificação de correlações estatísticas entre as curvas de distribuição das amostras e sua permeabilidade, utilizando a técnica de Partial Least Squares Regression (PLSR), que extrai componentes que maximizam simultaneamente a variância da distribuição e a sua covariância com a permeabilidade. (GELADI and KOWALSKI, 1986; MEHMOOD *et al.*, 2012).

$$k_{SDR} = a T_{2 lm}^b \phi_{RMN}^c \quad (7)$$

$$k_{Timur-Coates} = \left[\left(\frac{\phi_{RMN}}{C} \right)^a \cdot \frac{FFI}{BVI} \right]^b \quad (8)$$

$$k_{Han} = a \cdot \phi_{RMN}^b \cdot \frac{S_3^c \cdot S_4^d}{S_1^e \cdot S_2^f} \quad (9)$$

$$T_{2 lm} = 10^{\frac{\sum \log_{10}(T_2^{(i)}) \cdot \phi_{RMN}^{(i)}}{\sum \phi_{RMN}^{(i)}}} \quad (10)$$

1.6. Fluxo de Trabalho

O trabalho inicia com a coleta de dados petrofísicos a gás de porosidade (ϕ_{Gas}) e permeabilidade (k_{Gas}), que servirão de rótulos para validar as previsões dos modelos e suas possíveis caracterizações do reservatório. Com esses os valores de ϕ_{Gas} e k_{Gas} foi possível separar 5 grupos com base em suas HFU. Do total de 506 amostras, 70% das amostras de cada grupo foram selecionadas para os dados de treinamento e 30% para teste. Após a aquisição dos dados de RMN, foram realizadas modelagens para estimar a permeabilidade utilizando os modelos SDR, Timur-Coates, Rios, Han e um modelo MLP treinado para este trabalho. As estimativas de permeabilidade de cada modelo k_{model} e ϕ_{RMN} foram utilizados para obter as informações do reservatório (*FZI*, *RQI* e *HFU*) para cada modelo e comparados com os dados laboratoriais a gás. Por fim, estes dados também foram utilizados para obter a classificação dos tipos de poros seguindo o modelo propostos por Soto *et al.* (2010)

2. Metodologia

As amostras são compostas por plugs cilíndricos de até 50 mm com 25 mm de diâmetro. Das 506 amostras coletadas (Figura 3 - A, B e C), 493 são de plugs retirados da lateral de testemunhos de poços (Figure 1-C), e 13 são plugs

retirados de afloramentos (Figura 1-B), ambos da Formação Jandaíra, Bacia Potiguar (Figure 1-A) (ARAÚJO et al., 2023; LOPES et al., 2023). A obtenção dos dados de porosidade e permeabilidade a gás foi realizada de forma simultânea com o estado do gás ainda instável, sendo feita a correção de Klinkenberg (KLINKENBERG, 1941). O equipamento MesoMr12-060H-I da empresa Niumag (Figura 3-D) foi utilizado para aquisição dos tempos de relaxação T_2 (Figura 3-E) através da sequência CPMG, e o método SIRT para inversão da curva afim de adquirir a distribuição de tempos T_2 (Figura 3-F).

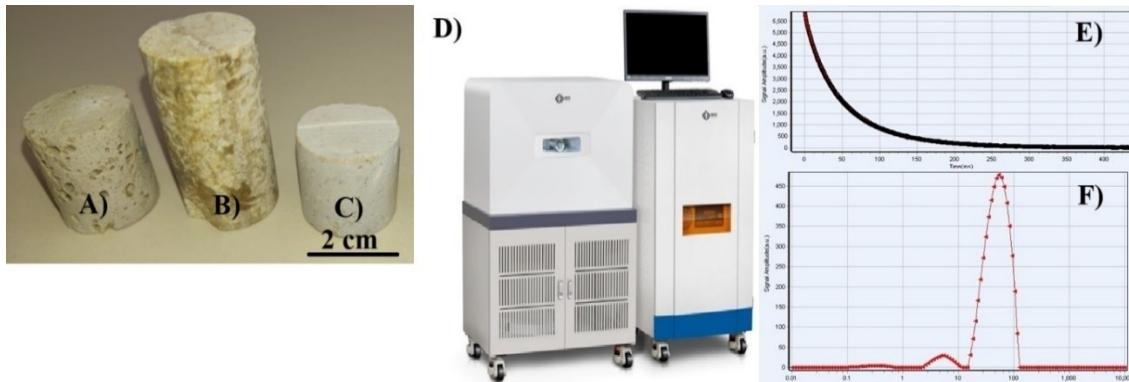


Figura 3 - Amostras de plugues retiradas de A) amostra de testemunho com porosidade visível, B) afloramento com estilolito, C) amostra de testemunho com baixa porosidade, D) equipamento MesoMr12-060H-I da Niumag, que permite a aquisição de E) curva de Relaxamento T_2 , e F) inversão de curva usando o método SIRT.

Fonte: Autores (2025)

Para identificar as HFU, utilizou-se o método KMeans da biblioteca Scikit-Learn (PEDREGOSA et al., 2015), inicialmente com 6 clusters. Como 2 HFU apresentaram valores muito semelhantes, elas foram unidas, e o conjunto passou a ter 5 HFU. A classificação em clusters separou os dados em subgrupos para treinamento e teste, utilizando o método *Stratified Shuffle Split*, também da *Scikit-Learn*. Esse método faz a separação pseudoaleatória com base nas classes, assim, 70% dos dados de cada HFU foram destinados ao treinamento e 30% ao teste, garantindo que todas as classes estivessem representadas em ambos os conjuntos.

A regressão linear múltipla, para ajuste dos coeficientes, é realizada por meio da transformação logarítmica dos modelos. Isso faz com que os expoentes de cada parâmetro se tornem multiplicadores dos logaritmos, que estão agora somados. Como se possui os valores da permeabilidade a gás, a regressão linear múltipla encontra esses coeficientes multiplicativos de cada logaritmo, ajustando assim o modelo aos dados de treinamento. A partir da obtenção dos coeficientes ajustados para o conjunto de dados de treinamento é possível prever os dados de teste. Para avaliar os erros das previsões da permeabilidade dos modelos é necessário avaliar o coeficiente de determinação (R^2) (11) e a Raiz do Erro Quadrático Médio com os valores em logaritmo (σ) (12) (Kenyon et al., 1988), uma vez que a permeabilidade está em ordens de magnitude diferentes.

$$R^2 = 1 - \frac{\sum(y_{real}^{(i)} - y_{previsto}^{(i)})^2}{\sum(y_{real}^{(i)} - \bar{y}_{real})^2} \quad (11)$$

$$\log_{10}(\sigma) = \sqrt{\frac{1}{N} \sum_{i=1}^N [\log_{10}(k_{modelo}^{(i)}) - \log_{10}(k_{Gás}^{(i)})]^2} \quad (12)$$

Para a escolha do MLP ótimo foi preciso determinar diversos conjuntos de hiperparâmetros e treiná-los em etapas, em que cada etapa eram informados os arranjos possíveis para que o GridSearchCV, que realizou o treinamento com subgrupos dos dados de treinamento com 5 K-fold, retornasse o que tivesse menor R^2 . As etapas de treinamento subsequentes a 1ª tinham conjuntos baseados nos melhores modelos anteriores. Os melhores modelos de cada etapa foram avaliados segundo

o erro σ no conjunto de dados de teste, e aquele que obteve menor σ foi escolhido como o modelo que melhor se ajustou ao conjunto de dados.

3. Resultados

A previsão de permeabilidade para cada modelo semiempírico comparados com os dados a gás estão ilustrados nas Figuras 4 e 5, para os dados de treinamento e teste respectivamente. Os clusters estão indicados por cores dos pontos nos gráficos, onde vermelha representa o cluster 0, o cluster 1 pela cor azul, o cluster 2 pela cor verde, o cluster 4 pela cor roxa e o cluster 5 pela cor laranja. O valor máximo, mínimo, médio da permeabilidade dos dados a gás e dos modelos, bem como o R^2 e o erro σ , para ambos os conjuntos de dados, estão descritos na Table 1. Foram realizadas 14 etapas de treinamento do modelo MLP, o número de arranjos variou entre 34560 e 11520 por etapa, totalizando 283392 arquiteturas treinadas. O modelo ótimo foi construído em 2 camadas com 48 perceptrons cada, com função de ativação Tangente Hiperbólica (Tanh) e método de retropropagação “Adam”.

Tabela 1 – Resultados dos valores máximos, mínimos, média, coeficiente R^2 e erro σ , de cada modelo para ambos os conjuntos de dados.

Modelos	Dados Treino					Dados Teste				
	Max	Min	Média	R^2	σ	Max	Min	Média	R^2	σ
Gás	786.347	0.001	4.212	1.00	1.00	517.279	0.001	4.623	1.00	1.00
SDR	4.067	0.0005	0.165	0.54	5.29	2.720	0.0001	0.176	0.52	5.86
Han	8.362	0.001	0.244	0.60	4.79	6.617	0.0002	0.260	0.58	5.24
Timur-Coates	3.400	0.001	0.177	0.58	4.92	2.273	0.0002	0.185	0.54	5.66
Rios	23278.648	0.002	66.393	0.71	3.74	15750.870	0.0025	107.808	0.56	5.49
MLP	661.253	0.002	2.904	0.79	3.07	839.999	0.0026	6.205	0.72	3.92

Fonte: Autores (2025)

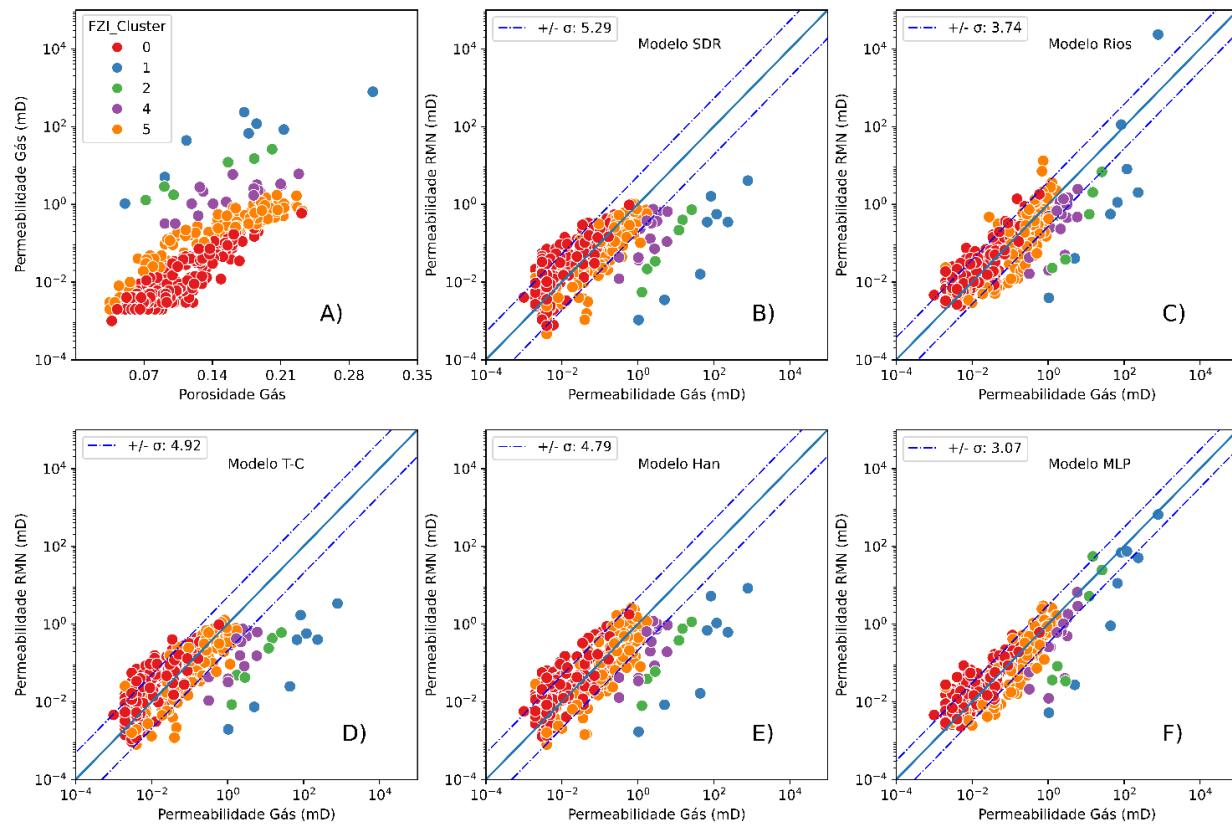


Figura 4 - Representação gráfica dos resultados de previsão da permeabilidade, avaliando apenas os dados de treinamento, dos modelos A) SDR, B) Rios, C) Timur-Coates (T-C), D) Han e E) MLP em relação com os dados a gás. As linhas pontilhadas indicam os limites do erro σ .

Fonte: Autores (2025)

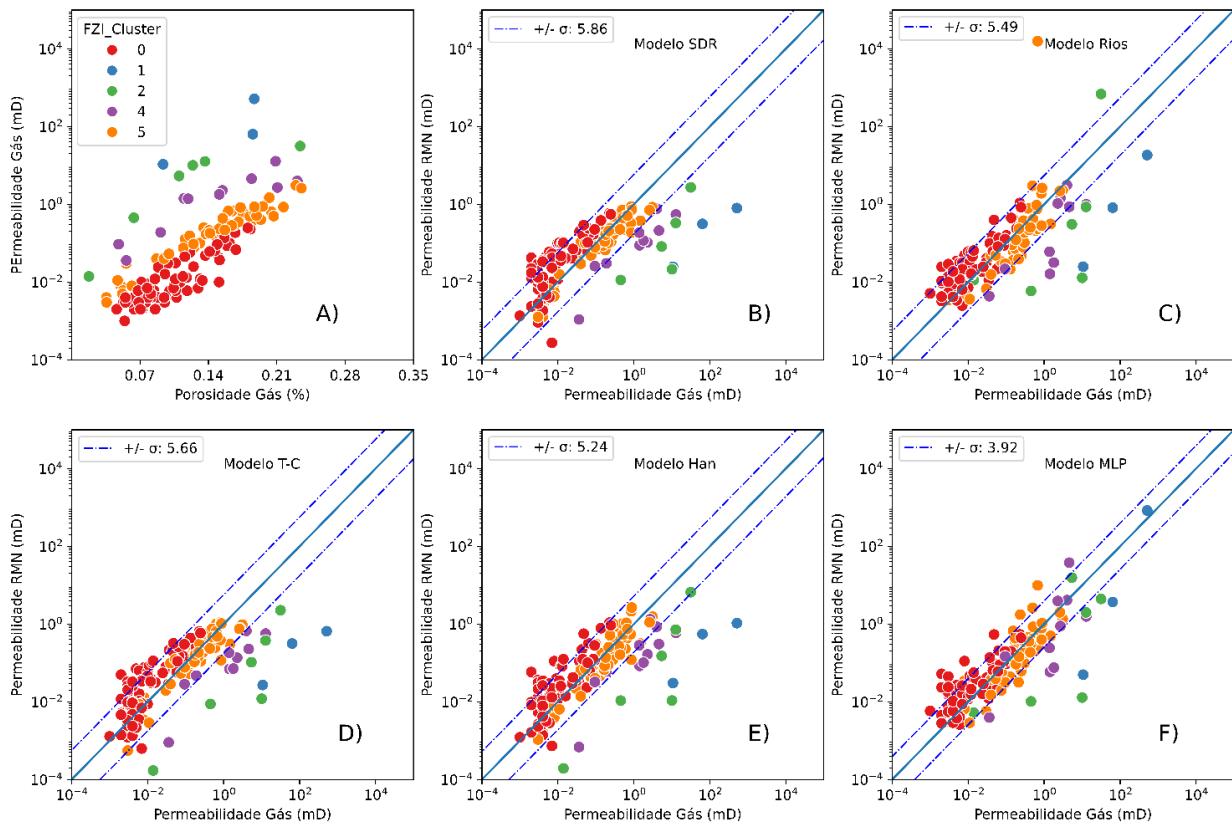


Figura 5 - Representação gráfica dos resultados de previsão da permeabilidade, avaliando apenas os dados de teste, dos modelos A) SDR, B) Rios, C) Timur-Coates (T-C), D) Han e E) MLP em relação com os dados a gás. As linhas pontilhadas indicam os limites do erro σ .

Fonte: Autores (2025)

A plotagem dos resultados obtidos através dos índices de RQI e FZI , com as retas HFU , estão apresentadas nas Figuras 6 e 7, para o conjunto de dados de treinamento e teste respectivamente. Os modelos herdaram a classificação a gás e tiveram seus cálculos estimados por cada cluster. Os valores dos coeficientes HFU , obtidos pelos índices FZI e RQI , determinados por cada cluster com base na prévia classificação dos dados a gás, para cada modelo estão descritas na Tabela 2. A separação dos tipos de poros por meio da curva sigmoidal (6) estão ilustradas nas Figura 8 e 9, para o conjunto de dados de treinamento e teste respectivamente.

Tabela 2 – Dados dos coeficientes HFU 's para cada cluster em ambos os conjuntos de dados. T-C significa Timur-Coates.

Clusters	Dados Treino						Dados Teste					
	Gás	SDR	Rios	T-C	Han	MLP	Gás	SDR	Rios	T-C	Han	MLP
0	0.10	0.19	0.17	0.19	0.18	0.17	0.10	0.21	0.19	0.20	0.19	0.20
1	3.46	0.23	3.05	0.25	0.32	1.79	4.33	0.25	0.63	0.24	0.30	3.14
2	1.48	0.23	0.55	0.26	0.31	1.18	1.61	0.23	1.43	0.25	0.31	1.13
4	0.58	0.20	0.27	0.21	0.24	0.36	0.65	0.21	0.29	0.22	0.24	0.68
5	0.24	0.21	0.25	0.22	0.23	0.24	0.24	0.21	0.98	0.22	0.22	0.25

Fonte: Autores (2025)

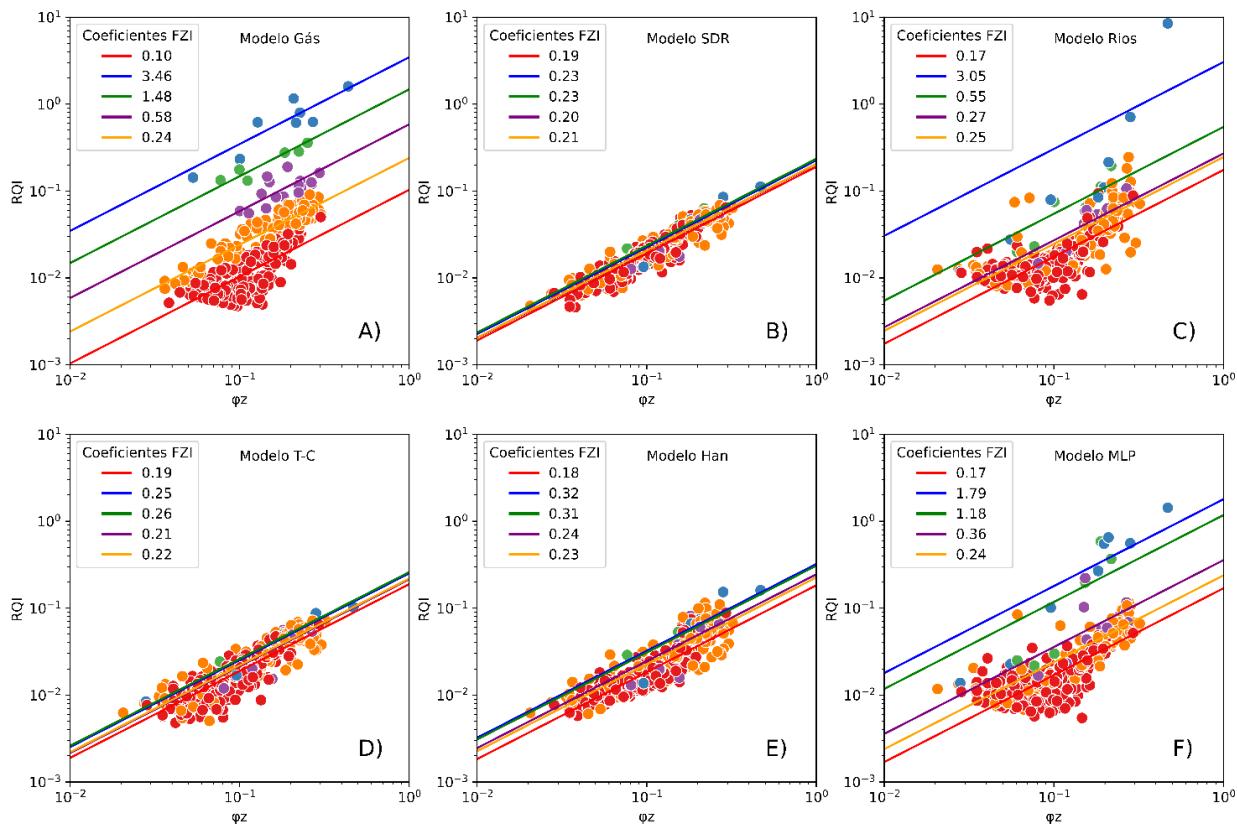


Figura 6 – Representação gráfica dos resultados do RQI e ϕ_z , avaliando apenas os dados de treinamento, dos dados A) Gás e para os modelos, B) SDR, C) Rios, D) Timur -Coates, E) Han e F) MLP. As linhas indicam os coeficientes HFU's.

Fonte: Autores (2025)

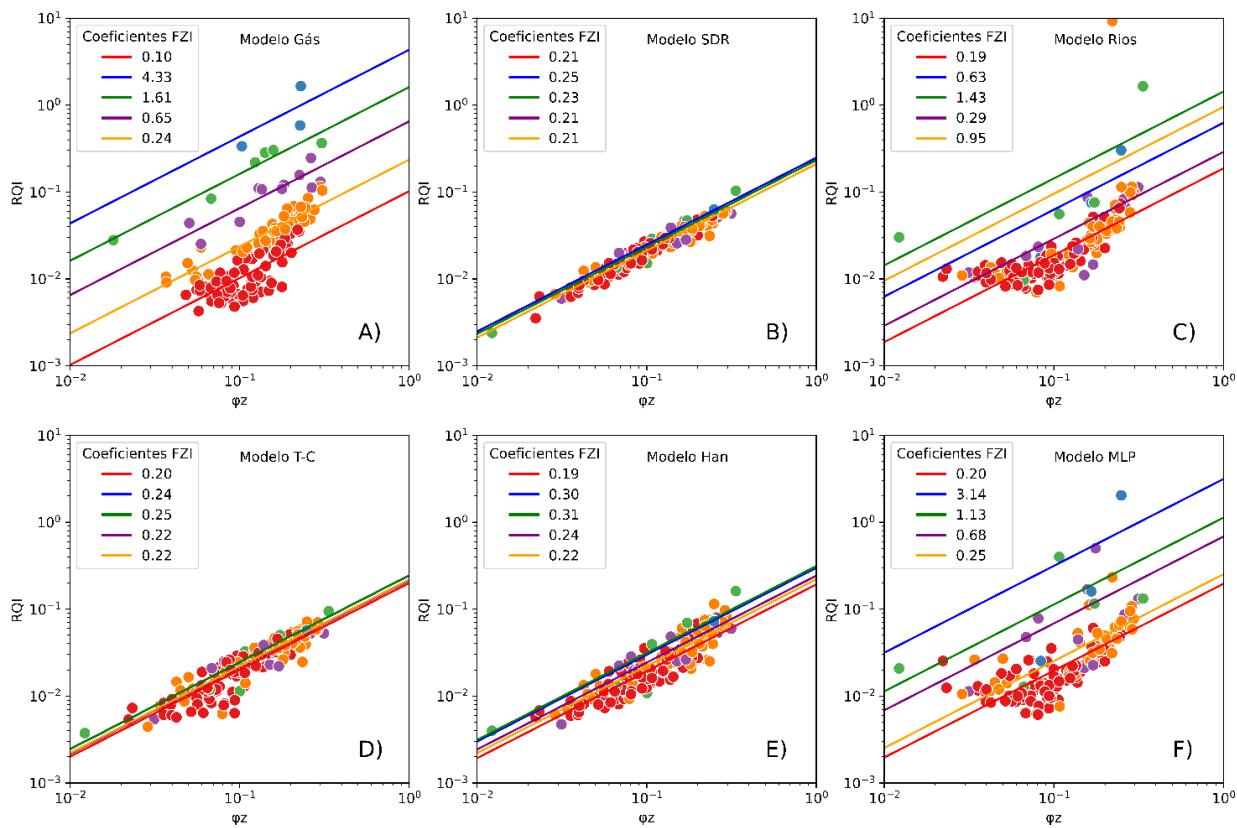


Figura 7 - Representação gráfica dos resultados do RQI e ϕ_z , avaliando apenas os dados de teste, dos dados A) Gás e para os modelos, B) SDR, C) Rios, D) Timur -Coates, E) Han e F) MLP. As linhas indicam os coeficientes HFU's.

Fonte: Autores (2025)

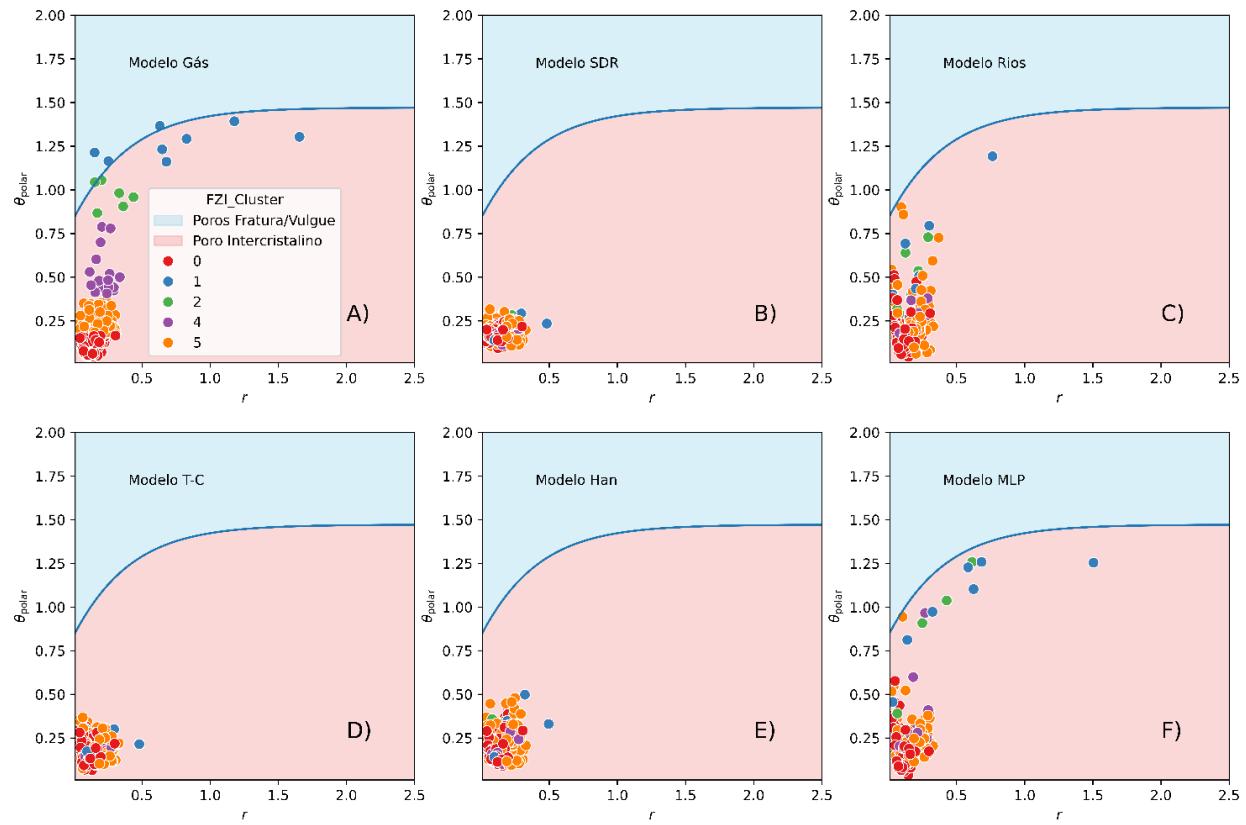


Figure 8 - Representação gráfica dos resultados do θ_{Polar} e r , avaliando apenas os dados de treinamento, dos dados A) Gás e para os modelos, B) SDR, C) Rios, D) Timur -Coates, E) Han e F) MLP. A linha indica a curva sigmoidal que separa os tipos de poros entre fraturas/vulgues (acima) e intercristalinos (abaixo).

Fonte: Autores (2025)

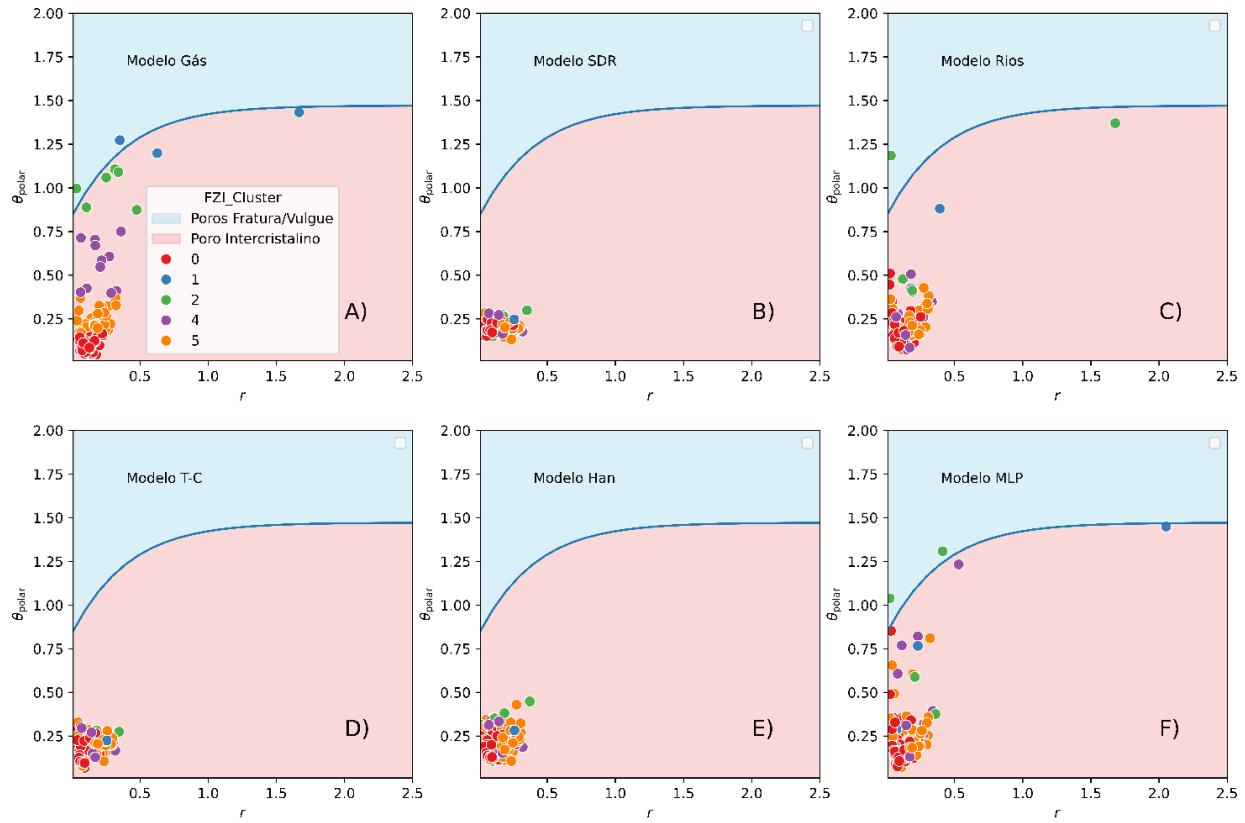


Figura 9 - Representação gráfica dos resultados do θ_{Polar} e r , avaliando apenas os dados de teste, dos dados A) Gás e para os modelos, B) SDR, C) Rios, D) Timur -Coates, E) Han e F) MLP. A linha indica a curva sigmoidal que separa os tipos de poros entre fraturas/vulgues (acima) e intercristalinos (abaixo).

Fonte: Autores (2025)

4. Discussão

Nosso objetivo é avaliar se modelos de predição de permeabilidade baseados em dados de RMN conseguem replicar as características observadas em dados laboratoriais. O primeiro passo após a obtenção dos dados laboratoriais é classificar as HFU utilizando o método K-Means, que se mostrou adequada, dado que o estudo foca em um único ambiente deposicional com alta complexidade em suas estruturas permoporosas, conforme estudos recentes (ASTSAURI *et al.*, 2024; EFTEKHARI *et al.*, 2024). Em contraste, Soto *et al.* (2010) que utilizaram diferentes reservatórios para separar as HFU, o que permitiu uma classificação mais homogênea e em nosso estudo (Figura 6 e 7) algumas ficaram com menos representação. Os tipos de poros através da comparação com a curva sigmoidal ajustada pelos parâmetros r e θ_{Polar} também foi bem ajustada por Soto *et al.* (2010) devido a escolha de vários ambientes, e no nosso estudo houve pouca representação dos poros “fraturas/vulgues” a partir da mesma curva sigmoidal. Outro ponto relevante do trabalho é o custo computacional para treinar um modelo, mas que devido a quantidade pequena de dados (354) e poucos dados de entrada (128) o custo de treinamento não foi tão elevado.

Ao avaliar as previsões de permeabilidade, observamos que, durante o treinamento, os modelos k_{Rios} e k_{MLP} apresentaram as melhores acurárias, com R^2 de 0,71 e 0,79, e erros σ de 3,74 e 3,07, respectivamente (Tabela 1). O modelo k_{Rios} , no entanto, superestima os valores máximos e médios de permeabilidade, enquanto o modelo k_{MLP} fornece valores mais próximos aos obtidos nas medições com gás. Além disso, o k_{MLP} teve bom desempenho no conjunto de teste, com R^2 de 0,72 e erro σ de 3,92, superando os outros modelos, que tiveram R^2 médio de 0,55 e erro σ de 5,56. Embora o erro σ

seja mais alto em comparação com estudos que utilizam RMN (KENYON *et al.*, 1988; SOUZA *et al.*, 2013; CHEN *et al.*, 2023), os resultados são satisfatórios, especialmente considerando a alta heterogeneidade das amostras. Esses resultados indicam que a seleção de parâmetros limitados da curva de distribuição T_2 não é suficiente para previsões precisas em ambientes complexos. Como a curva T_2 pode ser extensa, modelos como redes neurais artificiais conseguem captar padrões sutis e ajustes finos que modelos semiempíricos convencionais não conseguem modelar com a mesma precisão.

Nos dados de treinamento, apenas o modelo MLP conseguiu separar claramente essas cinco zonas, embora tenha subestimado o coeficiente da zona azul (cluster 1), com valor de 1,79 em vez de 3,46, o modelo de Rios, que obteve a melhor acurácia dentre os semiempíricos, separou quatro zonas, mas os clusters 4 e 5 apresentaram valores muito próximos (0,27 e 0,25), dificultando a diferenciação. Os demais modelos semiempíricos mostraram desempenho insatisfatório, com valores praticamente invariantes entre zonas, não permitindo distinguir mais de duas HFU. Nos dados de teste, o MLP novamente separou cinco zonas com boa precisão, exceto pelo cluster 0, que teve valor cerca de duas vezes maior que o esperado. O modelo de Rios, embora tenha separado cinco zonas, confundiu a correspondência dos clusters em relação aos dados de gás, ocasionando erros relevantes nas previsões com dados cegos. Os demais modelos mantiveram desempenho insatisfatório também nesse cenário. Esses resultados destacam a eficácia de modelos preditivos mais sofisticados, como o MLP, na interpretação da complexidade dos dados de RMN, contribuindo significativamente para uma caracterização mais precisa dos reservatórios.

A proximidade do modelo MLP em relação aos resultados obtidos com gás, ao se avaliar as HFU em ambos os conjuntos de dados, revelou que o uso de dados de RMN pode contribuir significativamente para uma caracterização precisa do reservatório, especialmente quando um modelo robusto é aplicado na predição de permeabilidade. Esse desempenho sugere que nosso conjunto de dados possui complexidade suficiente para simular de forma eficaz reservatórios desafiadores, reforçando ainda mais o potencial da técnica de RMN em contribuir significativamente para a modelagem e análise de reservatórios quando associada a abordagens preditivas avançadas.

A aplicação da função sigmoidal na separação dos tipos de poros não foi tão eficaz, pois poucas amostras ficaram acima da curva, indicando baixa correlação entre permeabilidade e cavidades ou fraturas. Embora algumas amostras contenham vulgues e estilólitos, fatores como a falta de conectividade dos vugs e a recristalização dos estilólitos reduzem a permeabilidade (ARAÚJO *et al.*, 2023), dificultando a classificação eficiente desses poros pela curva sigmoidal. No conjunto de dados a gás de treinamento, foram encontradas apenas 4 amostras com porosidade de fratura/vugs, sendo três no cluster 1 (azul) e uma no cluster 2 (verde). Para a avaliação qualitativa com a curva sigmoidal, as HFU estavam bem definidas, com menores valores de HFU correspondendo a amostras mais baixas. No entanto, nenhum modelo preditivo conseguiu distinguir com sucesso as amostras baseadas nos tipos de poros. Os modelos MLP (Figura 8-F) e Rios (Figura 8-C) apresentaram uma aproximação parcial da curva, com o MLP mostrando um ajuste visual melhor, embora ambos os modelos misturassem as HFU. No conjunto de teste, os resultados laboratoriais identificaram apenas duas amostras acima da curva (Figura 9-A), uma de cada cluster. O MLP previu duas amostras acima da curva, ambas do cluster 2 (Figura 9-F), enquanto o modelo Rios previu uma, também do cluster 2 (Figura 9-C). Outros modelos continuaram a ter dificuldades em se aproximar da curva sigmoidal.

Os dados de distribuição do tempo T_2 obtidos por RMN também podem ser relacionados ao tamanho da concentração dos spins e, consequentemente, ao tamanho dos poros (COATES *et al.*, 1999; DUNN *et al.*, 2002). Portanto, seria de se esperar que a RMN delimitasse esses intervalos com maior precisão do que os dados baseados em gás. No entanto, a predição do tipo de porosidade não é derivada diretamente dos dados de RMN, mas sim da modelagem da permeabilidade. A conversão do tempo T_2 para o tamanho dos poros não é direta para todas as amostras, o que significa que essas variáveis não são necessariamente correlacionadas. Como resultado, modelos semiempíricos tendem a simplificar demais as informações da RMN, levando a caracterizações excessivamente semelhantes entre si a fim de minimizar seus erros. Por outro lado, modelos preditivos que empregam abordagens estatísticas mais avançadas, como o proposto por Rios *et al.* (2011) e o modelo MLP, capturam melhor as características da permeabilidade. Assim, a caracterização da permeabilidade é mais refinada quando realizada com modelos estatísticos complexos. Em contraste, a avaliação dos tipos de porosidade para este reservatório deve adotar uma perspectiva diferente, em vez de se basear exclusivamente na modelagem ou na curva de distribuição do tempo T_2 .

5. Conclusão

Este estudo alcançou com sucesso seu objetivo ao obter dados laboratoriais com gás e compará-los com diversos modelos preditivos de permeabilidade, incluindo três modelos semiempíricos, um modelo estatístico e um modelo baseado em RNA. A análise foi conduzida em um ambiente geológico complexo, fornecendo indicadores, índices e classificações distintas de reservatórios, permitindo assim uma avaliação mais abrangente da previsão de permeabilidade desses modelos. Ao abordar esse contexto desafiador, o estudo não apenas comparou a precisão dos modelos, mas também avaliou sua influência na caracterização do reservatório. Entre os modelos analisados, o modelo MLP, treinado especificamente para este estudo, demonstrou a maior precisão. Esse modelo superou, tanto quantitativa quanto qualitativamente, os demais modelos amplamente empregados na indústria.

Os resultados destacam uma lacuna significativa na compreensão e utilização de dados de RMN para a previsão de permeabilidade. Quando esses dados não são corretamente interpretados, podem levar a caracterizações imprecisas dos reservatórios, impactando, em última instância, a tomada de decisões na exploração de hidrocarbonetos. Assim, a adoção de modelos mais sofisticados e robustos, como o MLP, surge como uma alternativa promissora para aprimorar a previsão de permeabilidade, conduzindo a interpretações geológicas mais confiáveis. Isso não apenas aprimora a compreensão das características do reservatório, como também auxilia a indústria na otimização da exploração de recursos, aumentando a eficiência e reduzindo as incertezas operacionais.

Possivelmente, a curva sigmoidal utilizada neste estudo pode precisar ser ajustada para representar melhor os dados avaliados, considerando as características específicas das amostras e a relação entre porosidade e permeabilidade. Além disso, uma caracterização detalhada dos tipos de porosidade seria essencial para permitir uma avaliação quantitativa mais precisa. Uma abordagem interessante seria utilizar diretamente a curva de distribuição do tempo T_2 obtida por RMN para classificar os tipos de porosidade, em vez de depender exclusivamente de modelos de permeabilidade. Esse método poderia fornecer uma visão mais direta sobre a estrutura e a conectividade dos poros, permitindo uma interpretação mais detalhada das propriedades da rocha.

Portanto, deixamos aqui algumas sugestões para realizações de trabalhos complementares futuros: (1) utilização de um campo amostral maior para realização de ajustes finos, (2) realizar a avaliação dos tipos de poros e ajustar a curva sigmoidal para os dados estudados, (3) utilizar diretamente os dados de RMN para obter as HFU e os tipos de poros.

Agradecimentos

O trabalho foi parcialmente apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e pelo Programa de Pós-Graduação em Geodinâmica e Geofísica (PPGG-UFRN).

A pesquisa foi realizada em associação com o projeto de P&D em andamento registrado como ANP 23505-1, “Processos e Caracterização de Rotas de Fluxo de Fluidos em Reservatórios Carstificados, Fraturados e Silicificados do Pré-Sal – Porocarste Fase II” (UFRN / UNB / UFPE / UFC / UFRA / IFRN / IFPB / Shell Brasil / ANP) – Porokarst Phase II – Processes and Characterization of fluid pathways in Karstified, Fractured and Silicified Reservoirs of the Presalt, patrocinado pela Shell Brasil sob a arrecadação de P&D da ANP.

Agradecemos também ao Centro de Computação de Alto Desempenho (NPAD/UFRN) por fornecer recursos computacionais relevantes, e aos Laboratórios de Propriedades Físicas das Rochas (LPFR) e de Engenharia de Reservatórios de Petróleo (LABRES) pela coleta dos dados petrofísicos.

Referências

- AMAEFULE, J. O. *et al.* Enhanced Reservoir Description: Using Core and Log Data to Identify Hydraulic (Flow) Units and Predict Permeability in Uncored Intervals/Wells. All Days, 1993. doi: <https://doi.org/10.2118/26436-ms>
- ARAÚJO, R. E. B. *et al.* Pore network characteristics as a function of diagenesis: Implications for epigenic karstification in shallow-water carbonates. Marine and petroleum geology, v. 149, p. 106094–106094, 2023. doi: <https://doi.org/10.1016/j.marpetgeo.2022.106094>
- ASTSAURI, T. *et al.* Utilizing machine learning for flow zone indicators prediction and hydraulic flow unit classification. Scientific Reports, v. 14, n. 1, p. 4223, 2024. doi: <https://doi.org/10.1038/s41598-024-54893-1>
- CANNON, S. Reservoir modelling : a practical guide. Hoboken, Nj: John Wiley & Sons, Inc, 2018.
- CARR, H. Y.; PURCELL, E. M. Effects of Diffusion on Free Precession in Nuclear Magnetic Resonance Experiments. Physical Review, v. 94, n. 3, p. 630–638, 1954. doi: <https://doi.org/10.1103/physrev.94.630>
- CHEN, X. *et al.* NMR-data-driven prediction of matrix permeability in sandstone aquifers. Journal of Hydrology, v. 618, p. 129147–129147, 2023. doi: <https://doi.org/10.1016/j.jhydrol.2023.129147>
- CHEN, S. *et al.* Study of Uncertainties in the Inversion Algorithms for Transverse Relaxation Distribution. 4th International Conference on Bioinformatics and Biomedical Engineering, 2010. doi: <https://doi.org/10.1109/icbbe.2010.5514753>
- COATES, G. R. *et al.* NMR Logging Principles and Applications. Gulf Professional. 1999.
- CÓRDOBA, V. C. A evolução da plataforma carbonática Jandaíra durante o Neocretáceo na Bacia Potiguar: Análise paleoambiental, diagenética e estratigráfica. 2001. PhD Thesis Universidade Estadual Paulista (UNESP), 2001.
- DE CASTRO, D. L. *et al.* Influence of Neoproterozoic tectonic fabric on the origin of the Potiguar Basin, northeastern Brazil and its links with West Africa based on gravity and magnetic data. Journal of Geodynamics, v. 54, p. 29–42, 2012. doi: <https://doi.org/10.1016/j.jog.2011.09.002>
- DUNN, K.-J. *et al.* Nuclear Magnetic Resonance. Elsevier, 2002.
- EFTEKHARI, S. H. *et al.* Hydraulic flow unit and rock types of the Asmari Formation, an application of flow zone index and fuzzy C-means clustering methods. Scientific reports, v. 14, n. 1, 2024. doi: <https://doi.org/10.1038/s41598-024-55741-y>
- GARIA, S. *et al.* A multivariate statistical approach in correlating the acoustic properties with petrophysics and mineralogy on sandstones. Geophysical Journal International, v. 230, n. 1, p. 160–178, 2022. doi: <https://doi.org/10.1093/gji/ggac061>

- GAVIDIA, J. C. R. *et al.* Bridging the gap: Integrating static and dynamic data for improved permeability modeling and super k zone detection in vuggy reservoirs. *Geoenergy Science and Engineering*, v. 241, p. 213152–213152, 2024. doi: <https://doi.org/10.1016/j.geoen.2024.213152>
- GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. *Analytica Chimica Acta*, v. 185, p. 1–17, 1986. doi: [https://doi.org/10.1016/0003-2670\(86\)80028-9](https://doi.org/10.1016/0003-2670(86)80028-9)
- GÉRON, A. *Mãos à Obra Aprendizado de Máquina com Scikit-Learn e TensorFlow*. Alta Books, 2021.
- HAHN, E. L. Spin Echoes. *Physical Review*, v. 80, n. 4, p. 580–594, 1950. doi: <https://doi.org/10.1103/physrev.80.580>
- HAN, Y. *et al.* A new permeability calculation method using nuclear magnetic resonance logging based on pore sizes: A case study of bioclastic limestone reservoirs in the A oilfield of the Mid-East. *Petroleum exploration and development*, v. 45, n. 1, p. 183–192, 2018. doi: [https://doi.org/10.1016/s1876-3804\(18\)30019-3](https://doi.org/10.1016/s1876-3804(18)30019-3)
- HINTON, G. E. *et al.* A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, v. 18, n. 7, p. 1527–1554, 2006. doi: <https://doi.org/10.1162/neco.2006.18.7.1527>
- KENYON, W. E. *et al.* A Three-Part Study of NMR Longitudinal Relaxation Properties of Water-Saturated Sandstones. *SPE Formation Evaluation*, v. 3, n. 03, p. 622–636, 1988. doi: <https://doi.org/10.2118/15643-pa>
- KLINKENBERG, L. The Permeability of Porous Media to Liquids and Gases. *Drilling and Production Practice*, American Petroleum Inst., pp. 200–213. 1941
- LOPES, J. A. G. *et al.* Three-dimensional characterization of karstic dissolution zones, fracture networks, and lithostratigraphic interfaces using GPR cubes, core logs, and petrophysics: Implications for thief zones development in carbonate reservoirs. *Marine and petroleum geology*, v. 150, p. 106126–106126, 2023. doi: <https://doi.org/10.1016/j.marpetgeo.2023.106126>
- LUCIA, F. J. *et al.* Carbonate Reservoir Characterization. v. 55, n. 06, p. 70–72, 2003. doi: <https://doi.org/10.2118/82071-jpt>
- MATOS, R. M. D. de. The Northeast Brazilian Rift System. *Tectonics*, v. 11, n. 4, p. 766–791, 1992. doi: <https://doi.org/10.1029/91tc03092>
- MEHMOOD, T. *et al.* A review of variable selection methods in Partial Least Squares Regression. *Chemometrics and Intelligent Laboratory Systems*, v. 118, p. 62–69, 2012. doi: <https://doi.org/10.1016/j.chemolab.2012.07.010>
- MEIBOOM, S.; GILL, D. Modified Spin-Echo Method for Measuring Nuclear Relaxation Times. *Review of Scientific Instruments*, v. 29, n. 8, p. 688–691, 1958. doi: <https://doi.org/10.1063/1.1716296>

PEDREGOSA, F. *et al.* Scikit-learn. GetMobile: Mobile Computing and Communications, v. 19, n. 1, p. 29–33, 2015. doi: <https://doi.org/10.1145/2786984.2786995>

RIOS, E. H. *et al.* Modeling rock permeability from NMR relaxation data by PLS regression. Journal of Applied Geophysics, v. 75, n. 4, p. 631–637, 2011. doi: <https://doi.org/10.1016/j.jappgeo.2011.09.022>

SOTO, R. B. *et al.* Pore-Type Determination From Core Data Using a New Polar-Transformation Function from Hydraulic Flow Units. All Days, 2010. doi: <https://doi.org/10.2118/136805-ms>

SOUZA, A. *et al.* Permeability prediction improvement using 2D NMR diffusion-t₂ maps. In: SPWLA 54TH ANNUAL LOGGING SYMPOSIUM, 2013, New Orleans, Louisiana. Society of Petrophysicists and Well Log Analysts. New Orleans, Louisiana: Society of Petrophysicists and Well Log Analysts, 2013.

TIAB, D.; DONALDSON, E. C. Petrophysics : theory and practice of measuring reservoir rock and fluid transport properties. Amsterdam; Boston: Elsevier/Gpp, Gulf Professional Publishing Is An Imprint Of Elsevier, 2016.

TIMUR, A. Pulsed Nuclear Magnetic Resonance Studies of Porosity, Movable Fluid, and Permeability of Sandstones. Journal of Petroleum Technology, v. 21, n. 06, p. 775–786, 1969. doi: <https://doi.org/10.2118/2045-pa>

WEI, H. *et al.* Nuclear Magnetic Resonance *T*₂ Distribution-Based Gas–Water Relative Permeability Prediction in Tight Sandstone Reservoirs: A Case Study on Central Sichuan Basin, China. Energy & Fuels, v. 38, n. 5, p. 3598–3608, 2024. doi: <https://doi.org/10.1021/acs.energyfuels.3c03972>

WOLPERT, D. H. The Lack of A Priori Distinctions Between Learning Algorithms. Neural Computation, v. 8, n. 7, p. 1341–1390, 1996. doi: <https://doi.org/10.1162/neco.1996.8.7.1341>