



CLASSIFICAÇÃO DE UNIDADES DE INJETIVIDADE POR MÉTODOS DE BINNING NÃO-SUPERVISIONADOS PARA ARMAZENAMENTO GEOLÓGICO DE CARBONO

Y. S. Tigre¹, B. R. Almeida¹, J. W. L. Silva¹, G. P. Oliveira¹

¹Laboratório TRIL, Centro de Informática, Universidade Federal da Paraíba (UFPB)

RESUMO

Na esteira da transição energética e dos processos de descarbonização, o presente artigo aborda o problema de classificação de dados cuja finalidade é obter partições para uma distribuição estatística de forma não supervisionada. Os intervalos de classe determinam unidades de injetividade que se identificam com regiões geológicas com qualidades distintas para armazenamento permanente de dióxido de carbono. Dois algoritmos de aprendizado de máquina para *binning* de dados são analisados: Blocos Bayesianos (BB) e Estimadores de Densidade de Núcleos (KDE). Os resultados obtidos fornecem explicabilidades diferentes para uma distribuição-base única.

Palavras-chave: Aprendizado de máquina; Análise de dados; Armazenamento geológico de CO₂; Descarbonização.

INTRODUÇÃO

A indústria de petróleo e gás está cada vez mais empenhada em equilibrar as demandas de sua cadeia produtiva com as questões climáticas e ambientais. Atualmente, as iniciativas de transição energética albergadas pelas tecnologias de captura e armazenamento de carbono (CCS) emergiram com enorme potencial para desempenharem um papel determinante para a redução de emissões de CO₂ na atmosfera (BOUCKAERT et al., 2021). Implementar estratégias eficientes de mitigação de emissões de CO₂ é um processo desafiador que depende da integração de fatores econômicos, sociais e ambientais. Uma das que têm sido postas como viáveis é o armazenamento geológico desse gás, principalmente em aquíferos salinos ou reservatórios depletados (INSTITUTE, 2018).

Focado em estudar métodos para qualificação de potenciais “armazéns” de CO₂, este artigo utiliza técnicas de aprendizagem de máquina para realizar processos de binning estatístico sobre distribuições de um composto de funções matemáticas que procuram medir a *Bayesian Blocks* é uma implementação em Python contida na

biblioteca *astropy*, que utiliza um histograma dinâmico, para atribuir a largura de banda ideal dos *bins* de forma não uniforme. A segunda abordagem consiste na técnica de Kernel Density Estimation, implementada a partir do módulo *sci-kit learn*, que se vale de uma mistura de componentes gaussianas pontuais que resulta em um estimador de densidade essencialmente não paramétrico.

Essas técnicas permitiram a construção de 8 gráficos, baseados em funções qualificadoras, para um determinado dataset de um reservatório. Como objetivo principal, buscamos por partições da função qualificadora que delimitarão intervalos de classe (*bins*) preferencialmente não uniformes. Esses intervalos são mapeados em tipos rochosos discretos identificáveis com regiões geológicas potenciais para armazenamento geológico de CO₂.

METODOLOGIA

O estudo conduz uma análise sobre os dados do modelo UNISIM-I-D (AVANSI and SCHIOZER, 2015), de onde são computados os valores de algumas propriedades da rocha (como *RQI* – Índice de Qualidade da Rocha, pressão, porosidade, etc.). Para garantir a validade e a confiabilidade dos resultados, foi necessário aplicar um pré-processamento aos dados do reservatório, verificando a existência de lacunas e valores *Not A Number* (NAN). Em seguida, os dados foram normalizados usando a regra min-max, para enfim serem processados pelos códigos.

A metodologia foi desenvolvida com base nas seguintes atividades:


1. Pré-processamento dos dados.
2. Escolha do método estimativo.
3. *Binning* dos dados.
4. Criação de classes de injetividade.
5. *Plot* dos gráficos.

RESULTADOS E DISCUSSÃO

Entre os gráficos obtidos na pesquisa, selecionamos dois que se concentram na característica *RQI*. Na Figura 1 podemos observar a partir do histograma de BB, o comportamento da rocha, que apresenta uma alta granularidade próximo à origem – o

que revela uma área de rocha em condições supostamente não ideais para a injeção – sucedida por de seções com menos ruído ao longo do eixo das abscissas, apresentando maior estabilidade.


Figura 1 – Binning dos Blocos Bayesianos



Fonte: dos Autores (2022)

Na Figura 2, a curva do KDE difere dos resultados obtidos do BB, revelando uma alta densidade de valores dispostos próximos à origem, porém com separação da distribuição em cinco classes apoiadas em pontos de mínimo relativos considerando-se uma margem de pontos vizinhos.

Figura 2 – Classes de Rocha Segundo J1 com KDE



Fonte: dos Autores (2023)

CONSIDERAÇÕES INICIAIS

Esta pesquisa concentrou-se na questão da descarbonização como parte de uma estratégia global para mitigar emissões, especialmente na aplicação de técnicas de classificação para identificar pontos de injetividade em regiões subterrâneas destinadas a armazenar com segurança o dióxido de carbono (CO₂) retirado da atmosfera. Para isso, foram utilizados métodos de aprendizado de máquina, que permitiram analisar as características da rocha e avaliar a sua adequação para contenção de CO₂. Esta pesquisa fornece informações importantes para decisões relacionadas à gestão e utilização de reservatórios de armazenamento de dióxido de carbono, ajudando a reduzir as emissões e a combater as mudanças climáticas. Além disso, demonstra a eficácia da aplicação de técnicas de Machine Learning na análise geológica de reservatórios e na avaliação da capacidade de armazenamento de CO₂.

REFERÊNCIAS

- AVANSI, G. D., SCHIOZER, D. J., 2015. Unisim-i: synthetic model for reservoir development and management applications. *International Journal of Modeling and Simulation for the Petroleum Industry* 9, 21–30.
- BOUCKAERT, S., et al., 2021. Net zero by 2050: A roadmap for the global energy sector. International Energy Agency.
- INSTITUTE, G.C., 2018. The global status of ccs 2018. <https://www.globalccsinstitute.com/resources/publications-reports-research/global-status-of-cs-report-2018/>.
- VANDERPLAS, J. **In-Depth: Kernel Density Estimation. Python Data Science Handbook**. 2016. Disponível em: <<https://jakevdp.github.io/PythonDataScienceHandbook/05.13-kernel-density-estimation.html>>. Acesso em: 4 de novembro de 2023.