

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

METODOLOGIA HÍBRIDA PARA PROJETO GEOTÉCNICO DE POÇO A PARTIR DE INTELIGÊNCIA ARTIFICIAL

AUTORES:

João Paulo Lima Santos¹, Lucas Veras de Siqueira¹, Lucas Pereira de Gouveia¹, Eduardo Toledo de Lima Júnior¹,
Rafael Dias², Fabio Sawada²
jpls@lccv.ufal.br

INSTITUIÇÃO:

¹Centro de Tecnologia, Universidade Federal de Alagoas, ²Petróleo Brasileiro S.A

METODOLOGIA HÍBRIDA PARA PROJETO GEOTÉCNICO DE POÇO A PARTIR DE INTELIGÊNCIA ARTIFICIAL

Resumo

A indústria de petróleo enfrenta desafios significativos na construção de poços em ambientes offshore, especialmente quando se considera a demanda por estudos prévios ao poço em locais extremos. A detecção precisa dos parâmetros do solo é imperativa para garantir a construção segura e eficiente de poços de hidrocarbonetos, uma vez que o sistema de revestimento condutor-superfície apresenta a função estrutural de fundação do poço, servindo de base para suporte estrutural durante a fase construtiva e em todo ciclo da operação do poço. No entanto, a realização de estudos de solo no ponto exato de interesse, muitas vezes, torna-se inviável em ambientes complexos, requerendo em muitas situações a realização de correlações a partir de pontos de ensaios específicos. O objetivo principal deste trabalho é introduzir uma solução moderna capaz de reduzir os custos associados ao longo do processo de construção de poços, mitigando erros humanos e prever as caracterizações geotécnicas para fundação de poços sem necessidade da realização de intensivos ensaios *in situ*. Dessa forma, este trabalho concentra-se na aplicação de técnicas de inteligência artificial e o uso de *Krigagem* para avaliar testes de resistência mecânica em solo a partir da extrapolação de dados em pontos geometricamente correlatos. A aplicação dessas técnicas permite obter uma estimativa dos parâmetros de interesse em pontos próximos. Nesse contexto, este estudo visa automatizar a aplicação de modelos de Inteligência Artificial, especificamente utilizando a técnica *Support Vector Machine* (SVM) em dados de ensaios de piezocone (CPTu), empregados para caracterização de resistência do solo para projeto geotécnico de poço. A implementação é realizada na linguagem de programação Python, e os resultados obtidos são comparados com técnicas de regressão tradicionais, ampliando a análise no contexto de estudos geotécnicos. Ao comparar os resultados obtidos com a abordagem tradicional de *Krigagem*, com foco na resistência não drenada do solo (S_u), foram identificados padrões que fornecem insights valiosos para a engenharia geotécnica de poço. Os resultados ressaltam a importância de uma abordagem integrada que combine métodos tradicionais e técnicas de inteligência artificial para obter resultados mais abrangentes e precisos na caracterização do solo e na previsão de parâmetros geotécnicos para construção de poços. Ao capitalizar os pontos fortes de cada abordagem e mitigar suas limitações individuais, uma estratégia híbrida pode oferecer uma visão mais completa do ambiente geotécnico, contribuindo para decisões mais fundamentadas na indústria de óleo e gás, reduzindo riscos e contribuindo para a segurança operacional.

Palavras-chave: Engenharia de poço, Fundação de poço, Geoestatística, Inteligência artificial.

Abstract

The oil industry, vital for the global energy supply, faces significant challenges in well construction in offshore environments, especially when considering the demand for pre-well studies in extreme locations. Accurate detection of soil parameters is imperative to ensure the safe and efficient construction of hydrocarbon wells, as the conductor-surface casing system serves the structural function of the well's foundation, providing structural support during the construction phase and throughout the well's operational cycle. However, conducting soil studies at the exact point of interest often becomes unfeasible in complex environments, requiring, in many situations, correlations based on specific test points. The main objective of this work is to introduce a modern and efficient solution for the oil and gas industry, addressing current limitations in well construction under adverse geotechnical conditions.

Therefore, there is a need for alternatives capable of reducing costs associated with the process, mitigating human errors, and predicting characterizations without the need for intensive in-situ testing. This work focuses on the application of artificial intelligence techniques and the use of Kriging to evaluate mechanical soil strength tests through data extrapolation from geometrically correlated points. The application of these techniques allows for estimating the parameters of interest at nearby points. In this context, this study aims to automate the application of Artificial Intelligence models, specifically using the Support Vector Machine (SVM) technique on piezocone test (CPTu) data, employed for soil strength characterization for well geotechnical design. The implementation is carried out in the Python programming language, and the results obtained are compared with traditional regression techniques, broadening the analysis in the context of geotechnical studies. By comparing the results obtained with the traditional Kriging approach, focusing on the soil's undrained shear strength (S_u), patterns were identified that provide valuable insights for well geotechnical engineering. The results highlight the importance of an integrated approach that combines traditional methods and artificial intelligence techniques to obtain more comprehensive and accurate results in soil characterization and prediction of geotechnical parameters for well construction. By leveraging the strengths of each approach and mitigating their individual limitations, a hybrid strategy can offer a more complete view of the geotechnical environment, contributing to more informed decisions in the oil and gas industry, reducing risks, and enhancing operational safety.

Keywords: Well Engineering, Well Foundation, Geostatistics, Artificial Intelligence.

Introdução

A indústria de óleo e gás desempenha um papel crucial na evolução econômica global, sendo vital para o fornecimento de energia. No entanto, esta responsabilidade traz consigo desafios e riscos significativos em todos os aspectos da exploração de hidrocarbonetos, exigindo abordagens ágeis e eficazes para enfrentar esses problemas. Recentemente, a inteligência artificial (IA) emergiu como uma alternativa promissora em diversos campos da engenharia, oferecendo soluções automatizadas e modernas para os desafios da indústria de óleo e gás.

Em particular, as análises de solo para início de poço têm se destacado como uma área de foco, dada a constante complexidade dos testes e a caracterização in situ. Dois testes fundamentais nesse contexto são o Cone Penetration Test (CPT) e o Piezocone Penetration Test (CPTu). Enquanto o CPT fornece informações essenciais sobre a resistência do solo, coesão e fricção interna através da penetração de um cone, o CPTu, ao incorporar medições de pressão de poros, adiciona detalhes sobre a permeabilidade e a compressibilidade do solo. Ambos desempenham um papel importante na caracterização completa do solo, influenciando as decisões no projeto de poços de hidrocarbonetos.

Este artigo propõe explorar a aplicação da inteligência artificial na abordagem de problemas de engenharia geotécnica relacionados à caracterização do solo. Utilizando dados provenientes do IBG Database (2020), abrangendo mais de 1339 parâmetros de testes geotécnicos, como CPT e CPTu, realizados em diferentes locais da Áustria e Alemanha, buscou-se desenvolver algoritmos capazes de extrapolar esses dados, permitindo a previsão de parâmetros em locais de interesse aos pontos de ensaio.

Além disso, o estudo concentra-se na comparação entre técnicas de interpolação geotécnica, com ênfase no uso de inteligência artificial, como Support Vector Machine (SVM), e a abordagem tradicional de Krigagem. Ao aplicar esses métodos aos dados do teste CPTu, com foco em parâmetros como resistência

ao cisalhamento não drenada, busca-se avaliar a eficácia e validade de cada abordagem, especialmente em relação aos parâmetros de solo em poços próximos. Uma análise é realizada para investigar a influência da distância nos resultados gerados por cada técnica, proporcionando insights para otimizar a caracterização geotécnica do solo e a tomada de decisões em projetos correlatos.

A aplicação de IA proposta surge como uma solução diferente para simplificar e otimizar a caracterização do solo em comparação com métodos estabelecidos, como a Krigagem, proporcionando uma abordagem possivelmente mais rápida e precisa. A utilização de dados extrapolados pode resultar em economia significativa na construção de poços, eliminando despesas extras associadas a estudos de teste de solo em pontos específicos. Isso possibilita aproveitar dados de poços de correlação já existentes nas áreas de interesse, contribuindo para uma abordagem mais eficiente e econômica.

Metodologia

Na fase preliminar da investigação do solo, que precede a perfuração de poços, o foco recai sobre a obtenção detalhada de informações geológicas específicas da área alvo. Para esse propósito, são empregados o ensaio de penetração de cone, conhecido como CPT (Cone Penetration Test), e sua variante aprimorada, o CPTu (Cone Penetration Test with Pore Pressure Measurement).

Conforme descrito por Lunne, Robertson e Powell (1997), o Cone Penetration Test (CPT) envolve a introdução gradual de um cone na ponta de uma série de hastes no solo a uma taxa constante. Durante esse processo, medições contínuas da resistência à penetração são realizadas, registrando parâmetros cruciais, como a resistência de ponta (q_c) e a resistência de atrito lateral (f_s). Esses dados desempenham um papel fundamental na identificação do ambiente geotécnico, fornecendo insights essenciais para o planejamento das operações de perfuração. A variante CPTu adiciona uma dimensão crítica: a medição da pressão dinâmica dos poros (u). Essa adição não apenas contribui para uma caracterização mais refinada do local, mas também desempenha um papel crucial na avaliação da resistência não drenada do solo (S_u). Esses dados são fundamentais para compreender as necessidades de suporte carga inerentes ao processo de perfuração e operação de poços.

A resistência não drenada é entendida como resistência ao cisalhamento oferecida pelo solo quando o mesmo é solicitado rapidamente, sem que haja condição de drenagem da água intersticial. Portanto, esse parâmetro é de foco central e será o principal elemento considerado nas demonstrações, aplicações e gráficos apresentados ao longo deste trabalho.

A Krigagem, um método estatístico amplamente utilizado na geoestatística, destina-se à estimativa de valores desconhecidos em locais não amostrados, fundamentando-se nos dados observados em pontos próximos. Conforme delineado por Carvalho & Assad (2005), este método faz uso da dependência espacial entre amostras vizinhas para estimar valores em qualquer posição dentro do campo, sem apresentar tendência e com variância mínima. Utilizando funções matemáticas, a Krigagem pondera valores amostrados, dando pesos maiores às posições próximas e menores às distantes (JAKOB, 2002). Neste estudo, emprega-se para previsão de variáveis regionais. Landim e Sturaro (2002) categorizam a Krigagem em dois tipos: Krigagem Simples e Krigagem Ordinária.

Segundo Russel e Norvig (2013), a Inteligência Artificial (IA) representa a capacidade de sistemas cibernéticos em replicar funções cognitivas humanas, destacando-se na resolução de problemas por meio

de aprendizado apoiado pela percepção. No contexto da indústria petrolífera, a IA é aplicada para reduzir o tempo de resolução de problemas e os custos associados. Ludermir (2021) propõe diferentes categorias de funcionamento da inteligência artificial, baseadas na natureza dos problemas abordados. A IA Focada utiliza algoritmos especializados em resolver problemas específicos, enquanto a IA Generalizada, que emprega técnicas de aprendizado de máquina, é considerada o estado atual da IA. A IA Superinteligente, uma visão futura, pressupõe algoritmos mais capazes que os humanos em quase todas as tarefas.

Dentro da categoria de IA Generalizada, destaca-se o Aprendizado de Máquina (AM), subdividido em aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, os algoritmos são informados sobre os resultados esperados, enquanto no aprendizado não supervisionado, esses resultados não são explicitamente fornecidos (ROSA, 2020). Silva (2021) destaca a importância da etapa de pré-processamento de dados no uso de algoritmos de Aprendizado de Máquina, que inclui a limpeza, transformação e redução dos dados. A limpeza assegura a ausência de dados em branco, a transformação adequa os dados para uso em modelos, e a redução busca maior eficiência sem comprometer a qualidade dos dados. O Support Vector Machine (SVM) é um algoritmo de aprendizado de máquina que se concentra em desafios de classificação ou regressão. O SVM busca identificar um hiperplano que melhor se adapte aos dados, minimizando a margem de erro entre previsões e valores reais. Sua versatilidade em lidar com problemas de regressão é valiosa em cenários de complexidade variável, oferecendo modelagem precisa e flexível para a previsão de valores contínuos, sendo escolhido com base em trabalhos anteriores com a mesma linha de pesquisa.

A metodologia deste trabalho consiste em utilizar os dados CPTu disponibilizados pelo Institute of Soil Mechanics, Foundation Engineering and Computational Geotechnics, provenientes de localidades específicas na Áustria. Essa abordagem é combinada com a linguagem de programação Python e técnicas de aprendizado de máquina. O propósito é realizar previsões utilizando um ponto já conhecido, validando esses resultados. Adicionalmente, busca-se fornecer previsões para novos pontos próximos aos dados de entrada, empregando o algoritmo Support Vector Machine para atender a ambos os objetivos. Adicionalmente, aplica-se metodologia de Krigagem Ordinária tanto para o ponto a ser validado quanto para o ponto a ser previsto. Isso permite realizar uma comparação entre os resultados obtidos pelos dois modelos.

Os dados são pré-processados para remoção de valores ausentes e escalonamento dos demais, visando otimizar a aplicação do SVM. Esse procedimento permite colocar todos os dados em escalas próximas, possibilitando que o modelo os interprete como igualmente relevantes. Adicionalmente, são utilizadas correlações para determinar os valores não calculados de algumas variáveis essenciais para aplicação na Krigagem, como o fator de cone (Nkt) e a resistência não drenada (Su), conforme as equações propostas por Mayne (2018):

$$Nkt = 10.5 - 4.6 * \ln(Bq + 0.1) \quad (\text{Eq. 1})$$


$$Su = \frac{qt - SIGMAvo}{Nkt} \quad (\text{Eq. 2})$$

Para as comparações feitas na validação de dados e previsões, é utilizado a fórmula de erro quadrático médio, dada como:

$$EQM = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2 \text{ (Eq. 3)}$$

Onde n é o número total de observações, Y_i é o valor observado da i -ésima observação e Y'_i é o valor previsto da i -ésima observação. A metodologia segue o fluxograma da Figura 1.

Figura 1 – Fluxograma do trabalho




Fonte: Autores (2024)

Resultados e Discussão

Na etapa inicial, foi realizada validação dos dados ao omitir um ponto conhecido, implementando a krigagem para a previsão das características nesse ponto. O ponto virtual escolhido foi o "373.flachgau" com coordenadas de 5218223.39 m UTM Norte e 332977.22 m UTM Leste. As Figuras 2 e 3 demonstram a previsão da resistência não drenada pela krigagem ordinária em comparação com o ponto real.


Figuras 2 e 3 – Resistência não drenada dos 6 furos conhecidos e previsão omitindo um furo



Fonte: Autores (2024)

Passando para a aplicação da IA na linguagem de programação Python, primeiramente, a figura 4 detalha a distribuição inicial dos dados CPTu, com enfoque na resistência não drenada.

Figura 4 - Distribuição inicial dos dados CPTu no Python




Fonte: Autores (2024)

Na implementação do Support Vector Machine (SVM) para prever a resistência não drenada do solo, foram cuidadosamente selecionados os hiperparâmetros: um kernel RBF, um parâmetro de regularização C igual a 1.0 e um termo de tolerância de erro (epsilon) fixado em 0.2. Essa escolha foi baseada em experimentação e validação cruzada para garantir um equilíbrio entre ajuste aos dados de treinamento e generalização para novos dados.

Além disso, foi verificada a ocorrência de overfitting, dividindo o conjunto de dados em treinamento e teste e monitorando o erro de treinamento durante o processo. A ausência de overfitting foi confirmada pelo ajuste adequado dos hiperparâmetros e validação do modelo em um conjunto de teste separado. Esses detalhes são cruciais para garantir a confiabilidade e eficácia do modelo, proporcionando uma base sólida para a discussão dos resultados. Após o pré-processamento, o SVM foi implementado com sucesso para prever o ponto oculto "373.flachgau". O gráfico resultante dessa previsão em comparação com o valor real pode ser visto na Figura 5.

Figura 5 - Comparação valores reais e previstos (SVM)



Fonte: Autores (2024)

Inicialmente, esperava-se que o SVM proporcionasse uma significativa melhoria na precisão das previsões em comparação com a krigagem. No entanto, os resultados revelaram um erro quadrático médio de aproximadamente 0,0973, o que pode ser considerado aceitável, mas não demonstra uma clara

superioridade sobre a técnica anteriormente utilizada. Essa disparidade nos resultados entre o SVM e a krigagem pode ser atribuída a diversas razões, que merecem uma análise detalhada. Uma possível explicação pode estar relacionada à sensibilidade dos hiperparâmetros escolhidos para o SVM, como o kernel RBF e os parâmetros de regularização C e epsilon. Apesar dos esforços em otimizar esses hiperparâmetros, é possível que não tenham sido escolhidos os valores ideais para o conjunto de dados específico, resultando em um desempenho subótimo do modelo.

Além disso, as características intrínsecas dos dados CPTu, como a complexidade das relações entre os parâmetros e a variabilidade espacial do solo, podem influenciar significativamente o desempenho do SVM. É importante considerar que o SVM é uma técnica de aprendizado supervisionado que pressupõe relações lineares ou não lineares entre os atributos de entrada e a variável de saída. Se essas relações forem complexas ou não lineares, o SVM pode não ser capaz de capturá-las efetivamente, levando a previsões menos precisas.

A análise do gráfico também revela que a zona final apresentou um ajuste pior em comparação com as zonas inicial e intermediária. Essa observação é fundamental para compreender as limitações de cada técnica em diferentes contextos geotécnicos. Enquanto a krigagem é uma técnica de interpolação espacial que se baseia em modelos geoestatísticos para estimar valores em locais não amostrados, o SVM é uma abordagem de aprendizado de máquina que busca identificar padrões nos dados e fazer previsões com base nesses padrões identificados. A zona final, que geralmente corresponde a áreas com menor densidade amostral ou maior variabilidade dos dados, pode representar um desafio para ambas as técnicas. No entanto, a figura comparativa revela que o SVM pode ter uma capacidade limitada de generalização nessas regiões, resultando em previsões menos precisas ou ajustes menos satisfatórios em comparação com a krigagem.

Conclusões

Este estudo comparou a eficácia da inteligência artificial (IA), usando o algoritmo SVM, com a técnica tradicional de Krigagem na previsão de parâmetros geotécnicos a partir de dados do Cone Penetration Test (CPTu) em ambientes específicos da Áustria e Alemanha. Embora a IA tenha sido vista como uma abordagem inovadora, os resultados revelaram que a Krigagem foi mais eficiente e fácil de ser utilizada, destacando sua confiabilidade e praticidade na interpolação geotécnica. No entanto, reconhece-se o potencial da IA e recomenda-se uma abordagem integrada, combinando métodos tradicionais com técnicas de IA para obter resultados mais abrangentes e precisos na caracterização do solo e na previsão de parâmetros geotécnicos.

Essa conclusão ressalta a importância de escolher a metodologia mais adequada para cada cenário geotécnico na indústria de óleo e gás, bem como o desenvolvimento de uma metodologia híbrida, conforme proposto no presente trabalho. Além disso, sugere-se a expansão do conjunto de dados incorporando uma variedade mais ampla de condições geográficas e parâmetros geotécnicos, bem como explorar outras técnicas de IA, como redes neurais e algoritmos de aprendizado profundo. Recomenda-se também a realização de validações experimentais para garantir a robustez dos resultados em cenários do mundo real, além da inclusão de outros parâmetros geotécnicos relevantes e a integração de dados multifontes para futuras pesquisas. Essas recomendações visam enriquecer a pesquisa atual e contribuir para avanços significativos na engenharia geotécnica aplicada à indústria de óleo e gás, proporcionando uma base sólida para decisões mais fundamentadas e eficazes no setor.

Agradecimentos

Agradecimento ao CNPq e Petrobrás pelo suporte ao desenvolvimento do trabalho.

Referências Bibliográficas

- CARVALHO, J. R. P.; ASSAD, E. D. Análise espacial da precipitação pluviométrica no Estado de São Paulo: Comparação de métodos de interpolação. Engenharia Agrícola, v. 25, n. 2, p. 377-384, 2005.
- CARVALHO, João Vítor & Eichelberger, Luiza & Oliveira, Camila & Bastos, Cezar & Alves, Antonio. (2019). Análise da resistência não drenada de diferentes solos artificiais obtida por ensaios de laboratório.
- DRUCKER H, BURGESS CJ, KAUMFMAN L, SMOLA AJ, VAPNIK V. Support vector regression machines In Advances in neural information processing systems 1997. p 155-161.
- EICHELBERGER, L. V. et al. Avaliação da resistência não drenada de dois solos artificiais por diferentes ensaios de laboratório. agosto de 2018.
- GATLIN, Carl, and R.L. Slobod. "The Alcohol Slug Process for Increasing Oil Recovery." Trans. 219 (1960): 46–53. doi: <https://doi.org/10.2118/1356-G>
- GIOVANINI, Adenilson. Semivariograma. Disponível em: <https://adenilsongiovanini.com.br/blog/semivariograma/>. 2022.
- JAKOB, Alberto Augusto Eichman. A Krigagem como Método de Análise de Dados Demográficos. Campinas, 2002.
- LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. Recife, 2021.
- LUNNE, T., Robertson, P.K. and Powell, J.J.M. (1997) Cone Penetration Testing in Geotechnical Practice. Blackie Academic & Professional, Londres, 312 p.
- MAYNE, P. W., & Peuchen, J. (2018). Evaluation of CPTU Nkt Cone Factor for Undrained Strength of Clays. Georgia Institute of Technology, Atlanta, Georgia, USA; Fugro, Netherlands.
- MEHTA, R. Big Data Analytics with Java. Birmingham: Packt Publishing Ltd, 2017.
- MELLO, J. M. de et al. Ajuste e seleção de modelos espaciais de semivariograma visando à estimativa volumétrica de Eucalyptus grandis. Scientia Forestalis, n. 69, p. 25-37, 2005. Acesso em: 20 mar. 2024.
- MONTEIRO, Hugo Leonardo Salomão. Análise de desempenho de diferentes leis de controle de vibrações torcionais em colunas de perfuração de poços de petróleo. 2012. Dissertação (Mestrado em Dinâmica das Máquinas e Sistemas) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012. doi:10.11606/D.18.2012.tde-26112012-084201. Acesso em: 2024-03-20.
- NORVIG, P., Russell S., Inteligência Artificial, editora Elsevier Brasil, 3ª edição, Rio de Janeiro, 2013, 1056p.