

**COMPARAÇÃO DE TÉCNICAS DE CLASSIFICAÇÃO NA PREDIÇÃO DA
CONCENTRAÇÃO DE SÓLIDOS NO ESCOAMENTO DE FLUIDOS COM
BASE EM DADOS DE VIBRAÇÃO.**

Bruno Lopes De Aguiar (bruno.epsg@gmail.com)

Marcus Felipe De Oliveira Quetez (marcusquetez@ufrj.br)

Moacyr Nogueira Borges Filho (m.borgesv8@hotmail.com)

Luis Americo Calçada (calçada@ufrj.br)

Claudia Miriam Scheid Pereira (scheid@ufrj.br)

Luiz Augusto Da Cruz Meleiro (meleiro@ufrj.br)

O processo de perfuração de poços de petróleo é complexo e sujeito a instabilidades, exigindo um monitoramento contínuo das propriedades do fluido por sensores de captação das variáveis [1]. Grossi et al. (2023 e 2024) mencionam que informações sobre fenômenos que ocorrem no fundo do poço, como instabilidade da parede e aprisionamento da broca, podem ser inferidas na superfície com base em análises da vazão e morfologia dos cascalhos gerados nesse processo. O transporte de sólidos em dutos fechados provoca alterações na frequência de vibração natural do escoamento de fluidos, podendo ser utilizado para monitorar a concentração de sólidos presentes na suspensão [3]. Tendo isso em vista, esse trabalho tem por objetivo principal a comparação de técnicas de classificação para a estimação de concentração de sólidos no escoamento de fluidos, ao passo que seja realizada de maneira

padronizada, ou seja, de modo que haja a entrada dos mesmos dados, etapas de pré-processamento e métricas. Avaliou-se, por meio de métricas de desempenho (Acurácia, AUC e F1 Score), a qualidade da classificação dos modelos de machine learning (kNN e Random Forest) na predição da massa de sólidos com base nas características dos sinais de vibração, coletados durante o transporte hidráulico de minerais. Os sinais foram processados por algumas técnicas, dentre as quais, temos a (i) Densidade Espectral de Potência (PSD), a qual permite classificar as partículas por meio de índice de energia e variabilidade de faixas de frequência [3], obtendo assim, uma frequência dominante, além de picos espectrais e relação sinal-ruído; (ii) Short-Time Fourier Transform (STFT), a qual divide o sinal em janelas de tempo relativamente curtas e aplica a transformada de Fourier em cada uma delas, extraíndo um espectrograma e a evolução temporal da energia espectral ali presente; e (iii) Continuous Wavelet Transform (CWT), utilizando de funções wavelet para adaptar, tanto janelas estreitas para altas frequências, quanto janelas largas para baixas frequências, de modo a simplificar e preservar a leitura de informações essenciais de maneira mais clara, sem a perda de dados cruciais. O kNN buscou os k vizinhos mais próximos, atribuindo um novo dado a classe comum entre eles, de modo simples e não paramétrico. Já o Random Forest realizou as previsões combinando os resultados de múltiplas árvores de decisão, lidando com dados complexos, ruidosos e aumentando a robustez na estimação da vazão. Os modelos avaliados demonstraram capacidade consistente em capturar a relação entre os sinais de vibração e os níveis de sólidos, entregando predições confiáveis com alta acurácia global (96% para Random Forest e 94% para kNN).

[1] C. D. Grossi et al., "Monitoring of the Drilling Region in Oil Wells Using a Convolutional Neural Network", em *Computer Aided Chemical Engineering*, vol. 52, 2023. doi: 10.1016/B978-0-443-15274-0.50215-8.

[2] C. D. Grossi, Y. N. Hummel, E. A. Moura, C. M. Scheid, L. A. Calçada, e L. A. C. Meleiro, "Development of computational vision methodologies for monitoring cuttings in the drilling fluid treatment system", *Brazilian Journal of Chemical Engineering*, vol. 41, no 4, 2024, doi: 10.1007/s43153-023-00389-w.

[3] Krauze, O., & Pawełczyk, M. (2016). Evaluation of copper ore granularity and flow rate using vibration measurements. In *IEEE MMAR 2016*, pp. 1267-1272.

Palavras-chave: fluidos de perfuração; redes neurais; monitoramento; controle; anomalias.