

GESTÃO DE RISCOS DE MEIO AMBIENTE E SEGURANÇA APLICADOS A PROJETOS OFFSHORE EM CONDIÇÕES HPHT (ALTA PRESSÃO E ALTA TEMPERATURA): ÁRVORE DE DECISÃO PARA CLASSIFICAÇÃO DE RISCOS

Ana Clara Moreira de Santana Santos¹; Ana Lúcia Barbosa de Souza²; Sara Oliveira de Araújo Marques³; Fernando Luiz Pellegrini Pessoa⁴

¹ Graduando em Engenharia Química; PRH ANP 27.1- Programa de Formação de Recursos Humanos para o Setor de Petróleo, Gás Natural e Biocombustíveis; anaclarasantana01@hotmail.com

² Mestre em Engenharia Química; SENAI-CIMATEC; ana.lbs@fiab.org.br

³ Mestre em Engenharia e Tecnologias Industriais; SENAI-CIMATEC; sara.souza@fiab.org.br

⁴ Doutor em Engenharia Química; SENAI-CIMATEC Salvador - BA; fernando.pessoa@fiab.org.br

RESUMO

A gestão de riscos é essencial para assegurar a segurança das operações offshore, particularmente em ambientes desafiadores como os de alta pressão e temperatura. Este artigo propõe o desenvolvimento de um modelo para classificação de riscos ambientais e de segurança em projetos de petróleo e gás. O modelo proposto tem como objetivo identificar e categorizar os riscos específicos associados a essas condições, proporcionando uma compreensão mais aprofundada e medidas de mitigação mais eficazes. A classificação dos riscos pode fornecer insights valiosos para a tomada de decisões durante o planejamento e execução dos projetos, contribuindo para a redução de acidentes e impactos ambientais. O framework deste trabalho apresenta abordagens inovadoras na classificação das situações de decisão e na caracterização dos riscos, utilizando a árvore de decisão e a função de classificação *Scikit-learn*.

PALAVRAS-CHAVE: Gestão de Riscos; Classificação de riscos; Petróleo e gás; Segurança.

1. INTRODUÇÃO

A exploração e produção de petróleo e gás em ambientes offshore enfrentam uma série de desafios complexos, especialmente quando se trata de projetos operando em condições de alta pressão e alta temperatura (HPHT).¹ Esses ambientes extremos não apenas exigem tecnologias avançadas e abordagens inovadoras, mas também impõem significativos desafios em termos de gestão de riscos de meio ambiente e segurança. Os projetos offshore HPHT representam um campo de operações onde a falha na gestão adequada dos riscos pode ter consequências catastróficas, tanto para o meio ambiente quanto para a segurança das equipes envolvidas. Vazamentos de óleo, explosões e danos aos ecossistemas marinhos são apenas alguns exemplos dos potenciais impactos negativos que podem ocorrer se os riscos não forem identificados e mitigados de forma eficaz, mas também a imagem da empresa ou concessionária de petróleo pode ser impactada.²

Dentro da indústria de petróleo e gás, existem vários métodos amplamente adotados para gerenciar os riscos relacionados à segurança e ao meio ambiente. Alguns desses métodos incluem Análise de Árvore de Eventos (ETA), Estudo de Perigo e Operabilidade (HAZOP), Análise de Perigos (AR), Análise de Árvore de Falhas (AAF), Modo de Falha, Efeitos e Análise de Criticidade (FMECA), HAZID (Identificação de Perigos), Análise de Monte Carlo, análise do Valor Monetário Esperado (EV), análise de sensibilidade e outros. de óleo e gás, esses métodos apresentam algumas lacunas e deficiências que ainda precisam ser abordadas e aprimoradas.³ Nesse sentido, o desenvolvimento de um modelo de gestão híbrido é uma oportunidade tecnológica para que o procedimento de gestão de riscos seja completo.

Este artigo tem como principal objetivo apresentar um método preliminar para classificação de riscos em projetos de petróleo e gás. Esse método envolve o uso da linguagem de programação Python, em conjunto com a biblioteca de machine learning Scikit-learn, para classificar os riscos em um ambiente industrial. Além disso, é utilizada a árvore de decisão como ferramenta auxiliar, representando as regras de decisão de forma hierárquica. Isso oferece uma abordagem alternativa para expressar as mesmas regras obtidas na construção de uma tabela de decisão. Para validar o modelo, é incorporada uma função de acurácia, que combina precisão e exatidão. Isso significa que os resultados obtidos devem não apenas ser precisos, mas também próximos ao valor de referência ou real utilizado como base.

2. METODOLOGIA

Este trabalho utilizou-se a ferramenta scikit-learn, que emprega aprendizado de máquina para classificar e prever riscos em projetos industriais de petróleo e gás. O programa treina um algoritmo para identificar o momento em que os riscos podem ocorrer e utiliza o método Random Forest para criar uma estrutura semelhante a um fluxograma, onde as condições são verificadas e o fluxo segue por ramos diferentes. Além disso, é incorporada a ferramenta Accuracy Score para avaliar a precisão do modelo em prever os riscos.

3. RESULTADOS E DISCUSSÃO

O algoritmo foi desenvolvido para classificar riscos de meio ambiente e segurança em projetos de petróleo e gás em alta pressão e alta temperatura. A biblioteca utilizada foi a “pandas”, biblioteca de software criada para linguagem Python para manipulação e análise de dados. A fim de testar a máquina, o algoritmo foi dividido em um conjunto de treino e outro conjunto de testes, a função “Train Test Split” no Sklearn tem como objetivo dividir o conjunto de dados (x, y) em um conjunto de treinamento (80%) e um conjunto de teste (20%). O Scikit-learn é uma biblioteca da linguagem python utilizada para predição de dados e neste caso está sendo utilizada para detectar a qual categoria pré-determinada um elemento pertence. A figura 1 mostra o algoritmo embrião para classificar riscos em um projeto de petróleo e gás:

Figura 1- Algoritmo para classificar riscos

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score, classification_report

# Exemplo de dados fictícios
dados = [
    [10, 20, 30, 'Catastrofe'],
    [15, 25, 35, 'Frequência'],
]

# Converter para DataFrame do Pandas
df = pd.DataFrame(dados, columns=['Feature1', 'Feature2', 'Feature3', 'Tipo_Risco'])

# Aplicar codificação One-Hot
df_encoded = pd.get_dummies(df, columns=['Tipo_Risco'], prefix='Tipo_Risco')

# Separar variáveis de entrada (X) e saída (y)
X = df_encoded.drop(['Tipo_Risco_Catastrofe', 'Tipo_Risco_Frequência'], axis=1)
y = df_encoded[['Tipo_Risco_Catastrofe', 'Tipo_Risco_Frequência']]

# Dividir dados em conjuntos de treinamento e teste
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Inicializar o modelo de Random Forest
modelo = RandomForestClassifier(n_estimators=100, random_state=42)

# Treinar o modelo
modelo.fit(X_train, y_train)

# Fazer previsões no conjunto de teste
previsoes = modelo.predict(X_test)

# Avaliar a precisão do modelo
acuracia = accuracy_score(y_test, previsoes)
print(f'Acurácia do modelo: {acuracia}')

# Exibir relatório de classificação
relatorio = classification_report(y_test, previsoes)
print('Relatório de Classificação:\n', relatorio)

Acurácia do modelo: 0.0
Relatório de Classificação:
      precision    recall  f1-score   support

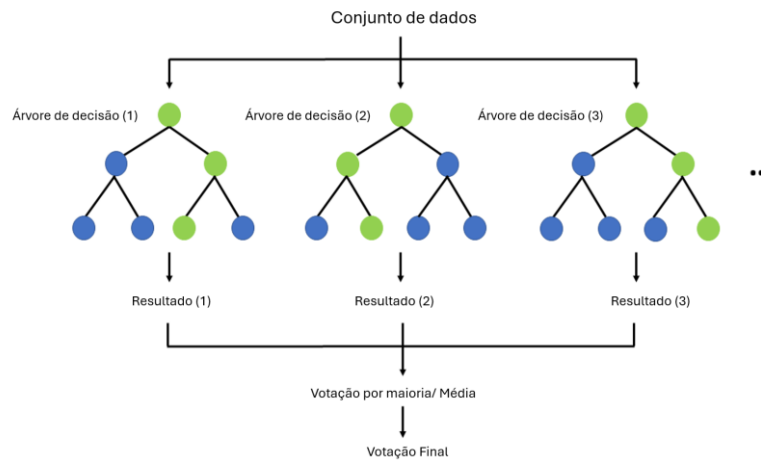
 0         0.00     0.00     0.00         0
 1         0.00     0.00     0.00         1

 micro avg     0.00     0.00     0.00         1
 macro avg     0.00     0.00     0.00         1
 weighted avg   0.00     0.00     0.00         1
 samples avg   0.00     0.00     0.00         1
```

Fonte- Própria

A fim de criar árvores de decisão, de maneira aleatória, o RandomForest também foi incrementado no algoritmo, esse método é utilizado para classificação. Para tarefas de classificação, a saída da “floresta” aleatória é a classe selecionada pela maioria das árvores. Para tarefas de regressão, a média ou previsão média das árvores individuais é retornada. A Figura 2 mostra a estrutura de uma árvore de decisão. A fim de validar o modelo, utilizou-se no programa uma função de acurácia, que é uma métrica de avaliação muito popular para descobrir a performance de um modelo de machine learning em uma tarefa de classificação. A Equação 1 mostra como é calculada a acurácia de um modelo:

Figura 2- Árvore de decisão



Fonte: Própria. Adaptado⁴.

$$Acurácia = \frac{VP+VN}{VP+VN+FP+FN} \quad (I)$$

- Verdadeiros Positivos (VP): classificação correta da classe Positivo;
- Falsos Negativos-Erro Tipo II (FN): erro em que o modelo previu a classe Negativo quando o valor real era classe Positivo;
- Falsos Positivos-Erro Tipo I (FP): erro em que o modelo previu a classe Positivo quando o valor real era classe Negativo;
- Verdadeiros Negativos (VN): classificação correta da classe Negativo.

4. CONSIDERAÇÕES FINAIS

Em síntese, a gestão de riscos ambientais e de segurança em empreendimentos offshore operando sob condições de alta pressão e alta temperatura (HPHT) constitui um fator primordial para assegurar a viabilidade e a segurança dessas operações. A adoção de instrumentos como árvores de decisão para a classificação de riscos representa uma abordagem metodológica e abrangente na identificação, avaliação e mitigação dos potenciais perigos inerentes a tais ambientes desafiadores. Ao promover uma estratégia proativa e holística na gestão de riscos, as organizações não apenas preservam a integridade do meio ambiente e das comunidades locais, mas também garantem a proteção da saúde e segurança de seus colaboradores. Sendo assim, esse estudo confirma que a metodologia de gestão de riscos aplicada em projetos de Petróleo e gás.

Agradecimentos

Agradecimentos à Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), ao Programa de Recursos Humanos da ANP (PRH 27.1), à FINEP, gestora do programa, e ao SENAI CIMATEC.

5. REFERÊNCIAS

¹HANNEGAN, Don. **Managed Pressure Drilling Applications on Offshore HPHT Wells**. Texas: SPE, Weatherford International Ltd,2011.

²AVEN, T. et al. **A decision framework for risk management, with application to the offshore oil and gas industry**. Norway: Reliability Engineering and System Safety 92,433–448, 2007.

³SANTOS, Ana Clara. **Analysis of Environmental and Safety Risk Management Applied to offshore projects under HPHT (High Pressure and High Temperature) conditions**. Brasil: IX SIINTEC,2023.

⁴ALI, Jehad. **Random Forests and Decision Trees**. IJCSI International Journal of Computer Science Issues, Vol. 9, Issue 5, No 3, September 2012.