

Machine Learning na Geotecnia: Treinamento para Tomada de Decisões em Monitoramento de Estruturas Geotécnicas

Marco Túlio Gurgel Mendonça

Engenheiro Geotécnico, Head5 Engenharia, Belo Horizonte, Brasil, marco.mendonca@head5.com.br

Lucas Ghion Zorzan

Engenheiro Geotécnico, Head5 Engenharia, Curitiba, Brasil, lucas.zorzan@head5.com.br

Silas Pereira da Silva Júnior

BIM Manager, Head5 Engenharia, Belo Horizonte, Brasil, silas.junior@head5.com.br

Marcelo Rossi Campos

Engenheiro Civil, Head5 Engenharia, Belo Horizonte, Brasil, marcelo.rossi@head5.com.br

RESUMO: A Inteligência Artificial (IA) é uma área da ciência da computação que se dedica ao desenvolvimento de sistemas que podem aprender e se adaptar sem a intervenção humana. A IA tem crescido exponencialmente nos últimos anos, com aplicações em diversas áreas, incluindo a engenharia geotécnica. Os dados de leituras de instrumentos geotécnicos são uma fonte valiosa de informações sobre o comportamento de obras de grande porte, tais como barragens de terra ou grandes escavações a céu aberto e subterrâneas. Esses dados podem ser utilizados para treinar modelos de IA que podem ser usados para uma variedade de tarefas, incluindo a previsão do comportamento de solos e rochas sob diferentes condições, como cargas, vibrações ou mudanças climáticas. Isso pode ajudar a melhorar a segurança de estruturas geotécnicas. Adicionalmente, os modelos de IA podem ser usados para identificar problemas ainda em estágios iniciais, como no caso de instabilidade de taludes. No tema da otimização de projetos geotécnicos, os modelos de IA podem ser usados para otimizar o projeto de estruturas geotécnicas, levando em consideração fatores como custo, segurança e desempenho. Este trabalho tem por finalidade demonstrar os procedimentos e resultados da utilização de dados de leituras de instrumentos geotécnicos - em especial para acompanhamento de deslocamentos e piezometrias de uma barragem - para treinamento de algoritmos de inteligência artificial, frisando o potencial desta ferramenta na melhoria contínua dos processos e da maneira de se desenvolver a engenharia geotécnica. Os estudos mostraram, de maneira prática, que esses modelos podem auxiliar a interpretar os dados de monitoramento de obras geotécnicas, tarefa essencial para garantir a segurança das estruturas.

PALAVRAS-CHAVE: Inteligência Artificial, Monitoramento, Machine Learning, Dados Geotécnicos.

ABSTRACT: Artificial Intelligence (AI) is an area of computer science dedicated to the development of systems that can learn and adapt without human intervention. AI has been growing exponentially in recent years, with applications in several areas, including geotechnical engineering. Data from geotechnical instrument readings is a valuable source of information about the behavior of large-scale structures, such as earth dams, large open-pit and underground excavations. These data can be used to train AI models that can be used for a variety of tasks, including predicting the behavior of soils and rocks under different conditions, such as loads, vibrations, or climate changes. This can help improve the safety of geotechnical structures. In addition, AI models can be used to identify problems at early stages, such as slope instability. On the subject of geotechnical project optimization, AI models can optimize the design of geotechnical structures, taking into account factors such as cost, safety, and performance. The purpose of this work is to demonstrate the procedures and results of using data from geotechnical instrument readings - especially for monitoring displacements and piezometry of a dam - for training artificial intelligence algorithms, emphasizing the potential of this tool in continuously improving geotechnical engineering processes and approaches. The studies have practically shown that these models can assist in interpreting geotechnical monitoring data, an essential task in assuring the safety of structures.

KEYWORDS: Artificial Intelligence, Monitoring, Machine Learning, Geotechnical Data

1 INTRODUÇÃO

O monitoramento de estruturas geotécnicas de grande porte, como barragens, aterros e escavações é um fator determinante na prevenção de incidentes geotécnicos. As inspeções visuais aliadas à um programa de instrumentação eficiente podem estabelecer comportamentos normais (ou não) para essas estruturas.

De acordo com Fusaro (2007), os programas de instrumentação de barragens no Brasil consistem no armazenamento de dados de leitura, cálculo e traçado dos gráficos que sistematizam os resultados obtidos em campo. Contudo, são poucos os programas que possuem um sistema de avaliação de comportamento integrado que permita avaliar tecnicamente as leituras dos instrumentos, se o comportamento da estrutura está normal ou anormal. Mesmo se tratando de quase duas décadas atrás do estudo, observa-se atualmente pouco avanço nesse aspecto, com sistemas possuindo pouquíssima análise crítica dos dados coletados. Em sua grande maioria, os programas de monitoramento apresentam apenas níveis de controle calculados pelos projetistas e são capazes apenas de indicar se um instrumento está com suas leituras abaixo ou acima dos níveis pré estabelecidos.

A Inteligência Artificial (IA) é um ramo da ciência da computação que estuda o desenvolvimento de algoritmos utilizados para evoluir e aprender sem interferência humana (Fatehnia & Amirinia, 2018).

O *Machine Learning*, ou Aprendizado de Máquina, visa construir algoritmos capazes de “aprender” com o alimento de dados, tornando-os capazes de tomar decisões e fazer previsões (Kohavi & Provost, 1998). Esses algoritmos são os mais utilizados para resolução de problemas de engenharia por sua capacidade de estabelecer padrões através de exemplos, mesmo sem nenhum conhecimento prévio sobre o assunto.

Com a popularização das IAs, principalmente com a ferramenta *ChatGPT*, criada pela *startup* americana *OpenAI*, a utilização desse recurso começou a ser difundido na sociedade em geral, inclusive no meio técnico de engenharia.

Diante disso, observa-se a possibilidade de utilizar o *Machine Learning* no para auxiliar na interpretação de dados de instrumentação geotécnica, diante do abastecimento da IA com dados suficientes para ensinar o algoritmo a tomar decisões e prever comportamentos normais ou não para as estruturas.

2. OBJETIVO

Esse artigo tem como objetivo avaliar a utilização de *Machine Learning* na ferramenta *ChatGPT 4.0*, desenvolvida pela *startup OpenAI*, para ensiná-lo a interpretar dados de instrumentação de barragens, como poropressões, recalques e vazões, para aplicá-lo no dia-a-dia do sistema de monitoramento e segurança dessas estruturas, além de prever comportamentos e identificar possíveis erros de leituras.

4. METODOLOGIA

Os dados de monitoramento da Barragem Alfa, uma estrutura de terra de uma usina hidrelétrica, foram empregados neste estudo. Ao longo de quase quatro décadas, a barragem tem sido monitorada por meio de piezômetros, marcos superficiais e medidores de vazão. Essa extensa série de dados, abrangendo aproximadamente 40 anos, proporciona uma base sólida para compreender o comportamento dessa estrutura em relação a poropressões, deformações e fluxos de água.

Primeiramente, para ensinar o *ChatGPT 4.0*, faz-se necessário enviar os dados para a ferramenta. Para esse trabalho, foram enviadas leituras de piezômetros e marcos superficiais. Foram extraídos os dados brutos dos instrumentos do sistema de monitoramento da estrutura, e enviados à ferramenta em planilhas eletrônicas formato *.xlsx*.

Deve-se esclarecer detalhadamente o que são as informações de todas as linhas e colunas da planilha, incluindo os títulos. Para os marcos superficiais, por exemplo, utilizou-se o seguinte *prompt*¹ de comando ao enviar a tabela:

“Insira essa planilha em seu banco de dados. A Linha 1 contém o nome do marco superficial. A Linha 2 contém os títulos dos dados e os dados em si estão dispostos da Linha 3 em diante. A primeira coluna é a data da leitura e a segunda coluna são as leituras do instrumento.”

Em seguida, o *ChatGPT* irá confirmar ou não se foi possível analisar o arquivo e os dados contidos. Ressalta-se aqui que a ferramenta não foi capaz de ler e interpretar os dados de todos os instrumentos instalados na barragem em um único arquivo. A IA só conseguiu interpretar as leituras com cada instrumento em arquivos separados, o que leva a acreditar que o programa possui dificuldade de analisar planilhas com maior quantidade de dados.

Caso a ferramenta consiga analisar o arquivo e entender as informações contidas na planilha, é possível solicitar informações simples sobre os dados enviados, como média, leituras máximas e mínimas, elaboração de gráficos etc. O comando abaixo foi suficiente para o *ChatGPT* elaborar o gráfico da Figura 1.

“Calcule as médias móveis das últimas três leituras de recalque e plote em um gráfico *versus* o tempo”.

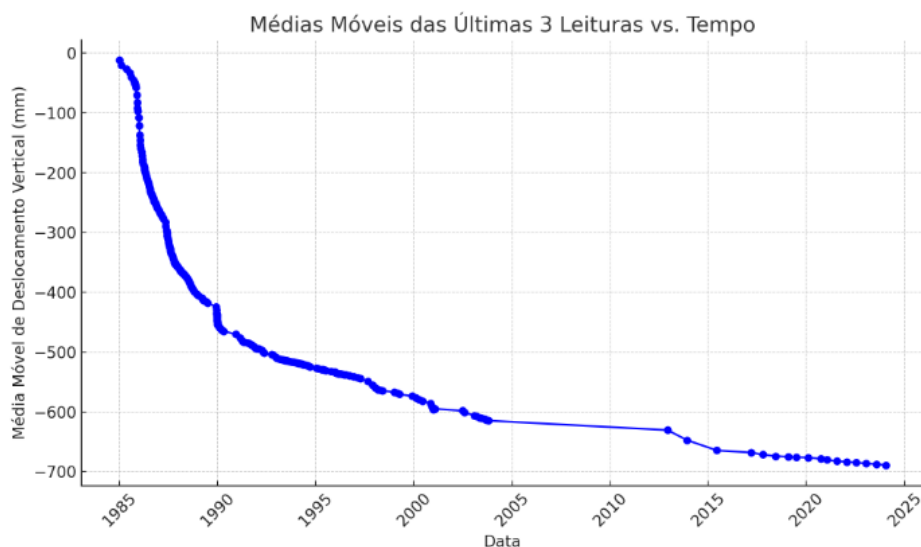


Figura 1. Gráfico das médias móveis das últimas três leituras *versus* tempo, elaborado pelo *ChatGPT* 4.0.

4.1 Identificação de possíveis erros de leituras

Para os piezômetros instalados no maciço, foi possível ensinar a IA a eliminar certos erros de leituras. Foram observadas leituras abaixo da cota de instalação de alguns instrumentos, que podem ser provenientes de equívocos nas leituras em si ou no lançamento no programa de monitoramento. Para a Barragem Alfa, as primeiras leituras nos piezômetros, datadas da década de 80, foram realizadas anteriormente ao enchimento do reservatório. Diante disso, as primeiras leituras correspondem à cota de instalação dos instrumentos. Foi utilizado o seguinte *prompt* de comando:

“Para os piezômetros, as primeiras leituras são iguais à cota de instalação dos instrumentos. Qualquer leitura abaixo desses valores são leituras erradas. Exclua quaisquer leituras abaixo da primeira leitura e plote o gráfico de cota piezométrica *versus* tempo. Indique também quais leituras em quais dias foram equivocadas.”

A Figura 2 apresenta os gráficos de leitura do piezômetro PP-11 antes e depois do comando de limpar leituras erradas.

¹ Entende-se como *prompt* comandos dados à Inteligência Artificial para auxiliar a obtenção de um modelo de resposta adequado.




Figura 2. Gráfico de leituras do PP-18, antes (A) e depois (B) do comando de eliminar leituras equivocadas, elaborado pelo *ChatGPT 4.0*.

A Inteligência Artificial indicou duas leituras equivocadas, nos dias 21/09/2005 e 20/10/2015.

Após o processo de treinamento, basta enviar os dados brutos de outros instrumentos para que a IA consiga identificar esses erros.

Podem ser identificados, também, outros tipos de enganos. Leituras muito altas, acima do nível do reservatório por exemplo, em sequência, ocorreram no instrumento denominado PP-18. Ao enviar os dados de leituras junto com os dados do N.A. a montante da barragem, foi possível ensinar ao ChatGPT a identificar essas anomalias e informar a data em que ocorreram.

Entretanto, as metodologias para a determinação do erro devem ser descritas detalhada e matematicamente. Mudanças repentinas no padrão não serão notadas a menos que sejam indicadas fórmulas matemáticas precisas, como, por exemplo, porcentagens fora da média ou leituras acima do desvio padrão calculado. Isso mostra-se uma limitação na capacidade de processamento de dados da IA.

4.2 Previsão de recalques

A previsão de recalques pode ser muito útil para analisar o monitoramento das deformações em barragens. Com grande quantidade de dados, tal como no caso da Barragem Alfa, é possível prever comportamentos e identificar se uma leitura é anômala ou não.

Para ensinar a IA a prever recalques, utilizou-se a metodologia de Asaoka (1978), que consiste num modelo gráfico simples para interpretação e extrapolação da curva de recalques e pode ser utilizado para

previsão de recalque primário para recalques superiores a 52,6% do recalque final. Pinto (2001) estabeleceu que o método de Asaoka é correto para a parcela do fenômeno que possa ser expresso por meio de uma equação exponencial, que parece ser o caso dos instrumentos instalados na Barragem Alfa.

Ressalta-se que essa é apenas uma das metodologias utilizadas para previsão de recalque e que o objetivo desse artigo é apenas verificar se a Inteligência Artificial é capaz de aprender e replicar o método, e não verificar qual metodologia é ou não é mais adequada para aplicação nesse caso.

Foram, então, ensinados os passos para que o ChatGPT aprendesse o método com os comandos a seguir.

“Primeiro, considere a primeira leitura como Dia 1 e as próximas como os dias subsequentes. Segundo, faça uma tabela Dia *versus* Leitura, com dias de 1000 em 1000. Caso não haja leituras exatamente nos dias 1000 ou 2000, interpole linearmente os valores dos deslocamentos verticais considerando as leituras próximas para maior assertividade”

A Tabela 1 apresenta os deslocamentos calculados pela IA nos dias múltiplos de 1000.

Tabela 1. Tabela com recalques nos dias múltiplos de 1000, elaborado pelo *ChatGPT 4.0*.

Dias	Deslocamento vertical (mm)	Dias	Deslocamento vertical (mm)
1000	-347,10	8000	-631,345
2000	-470,692	9000	-645,070
3000	-513,535	10000	-658,796
4000	-535,614	11000	-666,802
5000	-567,738	12000	-675,323
6000	-596,977	13000	-680,967
7000	-617,619	14000	-688,550

Seguindo com os *prompts* de comando:

“O Método de Asaoka só deve ser utilizado para recalques acima de 52,6% do recalque máximo. Para simplificação, considere que o recalque máximo é igual a última leitura do Marco Superficial. Desconsidere então qualquer recalque em módulo abaixo dos 52,6%.”

Para seguir com a metodologia, seria necessário plotar um gráfico s_{i-1} *versus* s_i , onde s é o recalque num tempo t , nesse caso definido nos múltiplos de 1000. Nesta etapa, houve dificuldade para a ferramenta entender o que seria necessário executar. Depois de variados testes para ensinar à IA, foi possível fazê-la entender utilizando comandos com exemplos. Foi utilizado:

“Como exemplo, supõe-se que o marco superficial tenha as seguintes leituras de recalques:

- Dia 1: 1 cm
- Dia 2: 1,5 cm
- Dia 3: 1,9 cm
- Dia 4: 2,3 cm
- Dia 5: 2,5 cm
- Dia 6: 2,6 cm

Plotar um gráfico com o seguinte raciocínio:

- Ponto 1: (x;y) = (Leitura dia 1;Leitura dia 2) = (1;1,5)
- Ponto 2: (x;y) = (Leitura dia 2;Leitura dia 3) = (1,5;1,9)
- Ponto 3: (x;y) = (Leitura dia 3;Leitura dia 4) = (1,9;2,3)
- Ponto 4: (x;y) = (Leitura dia 4;Leitura dia 5) = (2,3;2,5)

- Ponto 5 (x;y) = (Leitura dia 5;Leitura dia 6) = (2,5;2,6)

Agora, realizar o mesmo raciocínio com as leituras previamente organizadas com os dias em múltiplos de 1000.

Plotar também no gráfico a reta $y = x$, além da regressão linear dos pontos das leituras. Informar o coeficiente R^2 .

Com o exemplo utilizado, a IA conseguiu aprender a metodologia. A Figura 3 apresenta o gráfico de Asaoka elaborado pelo *ChatGPT* 4.0. O recalque máximo esperado calculado pela IA foi de 720,69 mm (em módulo) com um coeficiente R^2 de 0,995.

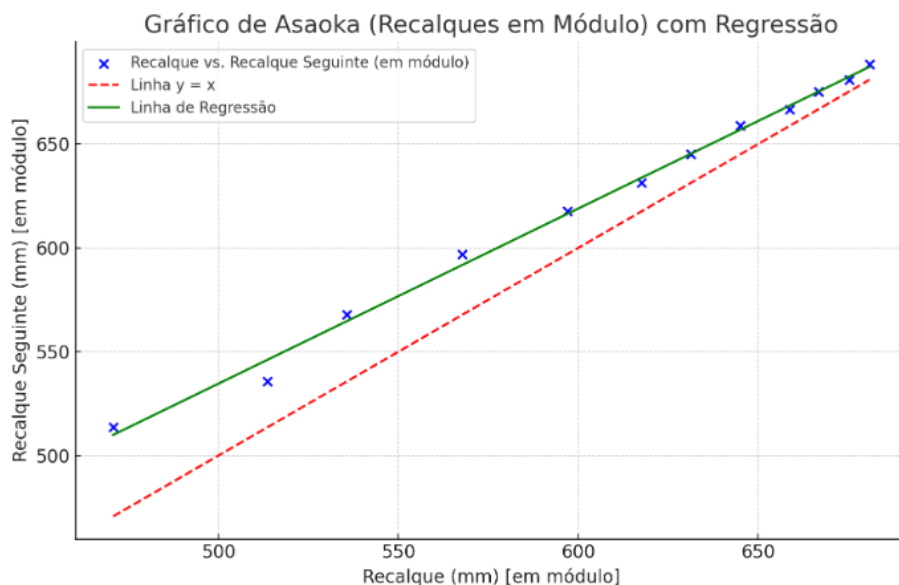


Figura 3. Gráfico da metodologia de Asaoka (1978), recalque *versus* recalque subsequente elaborado pelo *ChatGPT* 4.0.

Com a metodologia ensinada à ferramenta da OpenAI, basta enviar novos dados brutos de outro marco superficial e solicitar para utilizar o método seguindo os mesmos passos citados anteriormente. A Figura 4 apresenta o gráfico de Asaoka (1978) elaborado pela IA para o marco superficial MSN-02. Nesse caso, para testar o entendimento do *ChatGPT*, solicitou-se que a metodologia deveria ser aplicada considerando múltiplos de 500 dias para previsão dos recalques, o que foi executado corretamente.

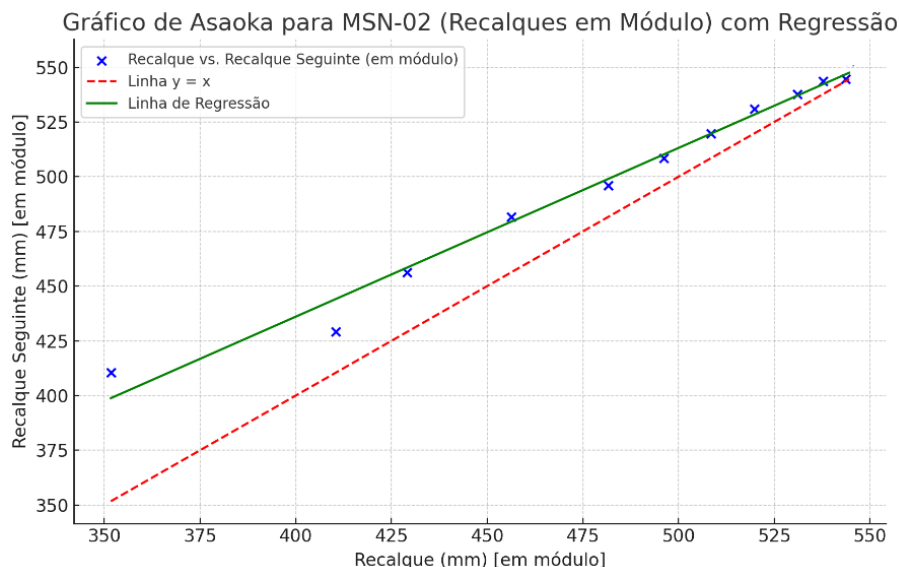


Figura 4. Gráfico da metodologia de Asaoka (1978) para o marco MSN-02, recalque *versus* recalque subsequente elaborado pelo *ChatGPT* 4.0.

Com a previsão realizada, a IA pode indicar nas próximas leituras se o recalque medido está dentro da normalidade (ou seja, dentro dos valores esperados pelo histórico de monitoramento) ou não para cada marco superficial.

Além disso, também foi possível ensinar ao *ChatGPT* como calcular a velocidade das deformações medidas pelos marcos entre cada leitura. Isso também pode ser utilizado para avaliar as leituras seguintes e informar se a velocidade de recalque está diminuindo ou aumentando.

5. DISCUSSÃO DOS RESULTADOS

Nota-se que a IA, se bem utilizada, pode ajudar a interpretar dados de monitoramentos de estruturas geotécnicas e até prevê-los. Para uma utilização assertiva da plataforma, foram observados os seguintes pontos:

- Existe certa dificuldade da plataforma para interpretar grande quantidade de dados em um arquivo único;
- O *ChatGPT* entende bem quando são enviados *prompts* com exemplos do que é necessário executar. Utilizar exemplos pode tornar o Aprendizado de Máquina mais simples;
- Deve-se ensinar métodos de cálculos com um passo de cada vez, para evitar processamentos mais complexos da IA, que podem resultar em erros;
- Tudo deve ser descrito detalhadamente para obter resultados assertivos;
- A IA só conseguirá notar erros de leitura ou tendências caso seja ensinado matematicamente como encontrá-las. Deve-se evitar ensinar abstrações;
- A Inteligência Artificial nunca irá substituir a análise técnica humana. As análises realizadas neste trabalho foram puramente matemáticas e não levaram em consideração conceitos de mecânica dos solos e engenharia geotécnica. Especialmente para o caso de análise de dados de instrumentação de estruturas, a avaliação crítica por uma equipe de engenheiros especializadas é essencial e, até o presente momento de evolução da Inteligência Artificial, insubstituível.

6. CONCLUSÕES

Observou-se que é possível ensinar a Inteligência Artificial noções básicas de monitoramento para auxiliar na interpretação dos dados da instrumentação. Utilizar a IA acoplada aos programas utilizados pode ser útil para uma análise preliminar dos dados e pode, inclusive, prever por si só tendência de recalques e estabelecer comportamentos normais e anormais para leituras.

Entretanto, é válido mencionar que, mesmo com uma quantidade grande de treinamento para interpretação, a IA não substitui, até o presente estágio de evolução desta técnica, a análise técnica humana. Os autores deste trabalho acreditam que a análise de dados de instrumentação é um serviço técnico de grande importância e que deve ser realizado por equipes de engenharia experientes, com capacidade de análise sistêmica e crítica na detecção de situações críticas. Recomenda-se, portanto, utilizar as ferramentas tecnológicas com cautela, como um complemento, nunca como verdade absoluta ou ferramenta única que substitua a análise crítica e a aplicação de conhecimentos de Engenharia.

Ademais, o envio de dados para o *ChatGPT* deve ser tratado com extrema cautela uma vez que, de acordo com sua política de privacidade, a plataforma grava todos os dados enviados para aprimorar e refinar suas respostas. A política de privacidade de dados da plataforma não está totalmente alinhada com a Lei Geral de Proteção de Dados (LGPD), o que pode resultar na ausência de garantias adequadas de confidencialidade e proteção do material enviado. Portanto, é crucial que os usuários estejam cientes dos riscos envolvidos ao enviar dados sensíveis de monitoramento geotécnico para o programa.

AGRADECIMENTOS

Agradecimento à Head5 Engenharia pelo fornecimento dos dados de instrumentação da Barragem Alfa e ao COBRAMSEG pela oportunidade de desenvolvimento desse trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- Asaoka, A. (1978). Observational Procedure of Settlement Prediction. *Soils and Foundations*, v.18, n. 4, p. 87-101.
- Fatehnia, M. & Amirinia, G. (2018). A review of Genetic Programming and Artificial Neural Network applications in pile foundations. *International Journal Of Geo-engineering*, [s.l.], 9(1), p 1-20.
- Fusaro, T. C. (2007) *Estabelecimento estatístico de valores de controle para a instrumentação de barragens de terra: Estudo de caso das barragens de Emborcação e Piau*. Dissertação de Mestrado Profissional, Núcleo de Geotecnia da Escola de Minas da Universidade Federal de Ouro Preto, 309 p.
- Kohavi, R. & Provost, F. (1998). Glossary of Terms. Machine Learning, *Kluwer Academic Publishers*, 30, p. 271-274.
- Pinto, C. S. (2001) Considerações sobre o método de Asaoka. Solos e Rochas, *ABMS*, v. 24 (1), p. 95-100.
- OpenAI OpCo LLC (2024) *Política de Privacidade*. Disponível em: < <https://openai.com/pt-BR/policies/privacy-policy/>> . Acesso em: 17 jun. 2024.