

Inteligência artificial e aprendizado de máquina na interpretação avançada de ensaios CPTu: uma revisão abrangente

Guilherme Tavares da Silva

Doutorando, UFSC, Florianópolis, Brasil, E-mail: eng.gtsilva@gmail.com

Henela Paula Nierwinski

Professora, UFSC, Florianópolis, Brasil, E-mail: helena.paula@ufsc.br

RESUMO: Este artigo mostra como Inteligência Artificial (IA) e Aprendizado de Máquina (AM) ajudam a tirar mais proveito dos ensaios CPT/CPTu, transformando muitos dados de campo em informações úteis para o projeto. É demonstrado, de forma simples, dois jeitos de usar essas técnicas: com exemplos já rotulados (para prever propriedades do solo ou classificar materiais) e sem rótulos (para descobrir padrões e organizar camadas). Foram reunidas experiências práticas que indicam ganhos claros: leitura mais consistente de limites entre camadas e montagem de modelos 3D do subsolo, além de previsões de V_s com ajuda de ferramentas que mostram os dados mais influentes na resposta do modelo. Também foram apontados onde os estudos divergem e por quê (diferenças de ambiente e de dados). Como conclusão, sugere-se que a IA/AM qualificam a decisão geotécnica quando os registros de CPTu têm boa curadoria e quando há transparência e validação em mais de um local.

PALAVRAS-CHAVE: CPTu ; Inteligência Artificial; Aprendizado de Máquina.

ABSTRACT: This paper shows how Artificial Intelligence (AI) and Machine Learning (ML) help extract more value from CPT/CPTu data, turning large field datasets into actionable insights. It is described, in plain terms, two ways these tools are used: with labeled examples (to predict soil properties or classify materials) and without labels (to find patterns and organize layers). Practical case highlights include more reliable layer boundary reading, building 3D subsurface models, and predicting V_s with tools that clarify which inputs matter most. It is also noted where studies disagree—and why (different settings and data). As bottom line, it is suggested that AI/ML enhance geotechnical decisions when CPTu records are well curated and results are transparent and validated across more than one site.

KEYWORDS: CPTu ; Artificial Intelligence; Machine Learning.

1 INTRODUÇÃO

O desenvolvimento da IA e do AM revolucionou diversas áreas da engenharia, inclusive a geotecnia. A grande variabilidade dos solos e a complexidade de suas interações com obras civis impõem desafios que podem ser abordados por algoritmos inteligentes capazes de extrair padrões de grandes volumes de dados (WANG *et al.*, 2023). A necessidade de previsões mais precisas e a redução da dependência exclusiva de ensaios laboratoriais incentivaram a adoção dessas ferramentas no cenário da engenharia geotécnica (NIERWINSKI *et al.*, 2023). Ademais, o advento de sensores e plataformas de coleta de dados em campo amplia a base informacional para o aprendizado de máquina, possibilitando análises preditivas em tempo real e com maior confiabilidade (ENTERAZI *et al.*, 2024).

É importante destacar que, embora a Inteligência Artificial seja amplamente associada a modelos de IA geral, como os que buscam simular o raciocínio humano e utilizam redes neurais profundas (deep learning) com milhões de parâmetros, o uso de IA na geotecnia possui foco diferente. Enquanto a IA geral visa desenvolver agentes autônomos com capacidade de generalização e raciocínio complexo, a aplicação da IA na geotecnia se orienta principalmente para a previsibilidade e reprodutibilidade de resultados (ENTERAZI *et al.*, 2024). Os profissionais da área buscam ferramentas confiáveis para auxiliar na tomada de decisão técnica, a partir de bases de dados muitas vezes limitadas, porém com forte relevância prática (WU *et al.*, 2021).

Assim, prioriza-se a utilização de algoritmos mais interpretáveis, com bom desempenho mesmo com amostras reduzidas e alta variabilidade, como modelos estatísticos clássicos, árvores de decisão e redes neurais superficiais (NIERWINSKI *et al.*, 2021). A distinção entre os objetivos da IA geral e da IA aplicada


à geotecnia é fundamental para compreender os desafios específicos enfrentados na adoção dessas ferramentas no campo da engenharia do solo. Neste contexto, este artigo visa sistematizar os principais avanços, aplicações e limitações da IA e do AM na geotecnia, com base em literatura científica recente e estudos de caso práticos (WU *et al.*, 2021).

2 FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

2.1 Definições e Classificações

O uso da Inteligência Artificial tem sido cada vez mais utilizado em diversas áreas de aplicação, incluindo a geotecnia. Esta é a sugestão, após realizar busca por artigos revisados por pares no Google academics. Para isto, foram usados os classificadores “artificial intelligence” e “geotechnic” e organizados por anos. Pode-se perceber a quantidade crescente de artigos, sugerindo um interesse crescente no assunto, conforme a figura 1.

Figura 1. Quantidade de artigos publicados usando as palavras “artificial intelligence” e “geotechnic”



A Inteligência Artificial (IA) é um campo da ciência da computação dedicado à criação de sistemas capazes de executar tarefas que normalmente exigiriam inteligência humana. Isso inclui habilidades como aprendizado, raciocínio, resolução de problemas, percepção e compreensão da linguagem.

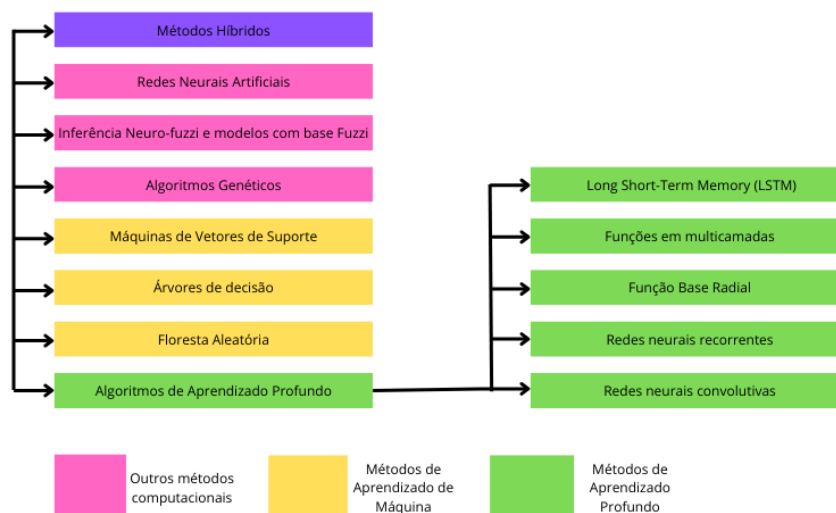


Figura 2. Análises computacionais com uso de Inteligência Artificial (Garsole *et. al.* adaptado, 2023)

A figura 2 demonstrou uma parte dentro do vasto escopo da IA, onde o Aprendizado de Máquina (AM) se destaca como um subcampo crucial. O AM se concentra em desenvolver algoritmos que permitem aos sistemas "aprender" a partir de dados, identificar padrões complexos e, a partir desses padrões, fazer



previsões ou classificações sem serem explicitamente programados para cada tarefa específica (WU *et al.*, 2021).

Essa capacidade de aprendizado é o que torna o AM particularmente valioso para a geotecnia, onde a complexidade e variabilidade dos dados são inerentes (NIERWINSKI *et al.*, 2023). Os algoritmos de AM podem ser categorizados em diferentes tipos, dependendo da natureza do problema e dos dados disponíveis. As duas categorias principais são o aprendizado supervisionado e o aprendizado não supervisionado. No aprendizado supervisionado, os algoritmos aprendem a partir de um conjunto de dados rotulados, ou seja, dados onde a saída correta já é conhecida.

O objetivo é que o modelo generalize esse conhecimento para prever saídas em novos dados (PHU *et al.*, 2023). Já no aprendizado não supervisionado, os algoritmos trabalham com dados não rotulados, buscando identificar estruturas, padrões ou agrupamentos intrínsecos nos dados. Em geotecnia, isso inclui, por exemplo, a classificação/segmentação de camadas a partir de CPT/CPTu com k-means ou outros métodos, sem rótulos prévios, para revelar padrões estratigráficos e comportamentais que complementam índices empíricos como o I_c (WU *et al.*, 2021) (NIERWINSKI *et al.*, 2023).

2.2 Algoritmos Supervisionados (machine learning)

Os algoritmos de aprendizado supervisionado são amplamente empregados na geotecnia para prever propriedades, classificar solos ou estimar fatores de segurança, pois há um "resultado" ou "rótulo" esperado associado aos dados de entrada. De acordo com Wu *et al.* (2021), dentre os mais comuns e eficazes, destacam-se:

Máquinas de Vetores de Suporte (SVM): As SVMs são algoritmos robustos para classificação e regressão. Na classificação, elas funcionam encontrando um hiperplano ótimo que separa as classes de dados com a maior margem possível. Isso as torna particularmente úteis na classificação de solos, como a distinção entre argilas, siltes e areias com base em suas propriedades índice, ou na análise de estabilidade de taludes, onde podem classificar taludes como estáveis ou instáveis. Um exemplo seria o uso de SVM para classificar tipos de solo com base em dados de ensaios de cone (CPT), correlacionando os parâmetros medidos com as categorias de solo conhecidas, auxiliando na elaboração de perfis geotécnicos mais precisos. Além disso, SVMs têm sido empregadas na previsão de deformações em grandes escavações e maciços rochosos, oferecendo modelos precisos que auxiliam na redução de riscos.

Árvores de Decisão (AD): As árvores de decisão são modelos de aprendizado supervisionado que dividem o espaço de dados em regiões, com base em uma série de regras de decisão simples. Elas são altamente interpretáveis, o que é uma vantagem significativa na engenharia geotécnica, onde a justificativa técnica das decisões é fundamental. Podem ser usadas para problemas de classificação (por exemplo, se um talude é estável ou não) ou regressão (por exemplo, prever a resistência de um solo). Sua aplicação na estabilidade de taludes é notável, superando métodos clássicos determinísticos em termos de acurácia quando bem calibradas. Por exemplo, uma árvore de decisão pode ser construída para prever o fator de segurança de um talude com base em parâmetros como altura do talude, ângulo de inclinação, e propriedades de resistência do solo.

Regressão Logística e Linear: Embora sejam métodos estatísticos clássicos, são amplamente utilizados no contexto do AM para estimativas diretas. A regressão linear busca modelar a relação entre uma variável dependente contínua e uma ou mais variáveis independentes, assumindo uma relação linear. A regressão logística, por sua vez, é usada para problemas de classificação binária, estimando a probabilidade de um evento ocorrer. Essas regressões são particularmente eficazes para trabalhar com dados tabulares e podem fornecer uma base sólida para modelos preditivos, especialmente quando integradas com técnicas de AM mais modernas. Por exemplo, a regressão linear pode ser empregada para estimar a permeabilidade do solo com base em dados de granulometria e índice de vazios.

2.3 Algoritmos Não Supervisionados (deep learning)

Os algoritmos de aprendizado não supervisionado são cruciais quando não há rótulos predefinidos nos dados, e o objetivo é descobrir estruturas subjacentes, padrões ou agrupamentos. Na geotecnia, isso é valioso para a caracterização de locais, identificação de zonas homogêneas e redução da dimensionalidade de grandes conjuntos de dados.



K-means: Este é um algoritmo de agrupamento que particiona um conjunto de dados em K grupos (clusters), onde cada ponto de dados pertence ao cluster cujo centro (centróide) é o mais próximo. É amplamente utilizado na geotecnia para agrupar solos ou condições geotécnicas similares. Por exemplo, em uma investigação geotécnica extensa, o K-means pode ser aplicado a dados de sondagens (SPT, CPT) para identificar zonas com características de solo semelhantes, facilitando a elaboração de perfis geotécnicos e o planejamento de obras civis. Alguns estudos demonstram a eficácia do K-means na classificação de solos, resultando em agrupamentos claros e úteis para a tomada de decisão.

PCA (Principal Component Analysis): A Análise de Componentes Principais (PCA) é uma técnica de redução de dimensionalidade. Ela transforma um conjunto de variáveis possivelmente correlacionadas em um conjunto de variáveis não correlacionadas, chamadas componentes principais, mantendo a maior parte da variância dos dados originais. Na geotecnia, a PCA é inestimável para lidar com grandes bancos de dados geotécnicos, identificando as variáveis principais que mais contribuem para a variabilidade dos dados e simplificando a análise sem perder informações críticas. Por exemplo, em um conjunto de dados com dezenas de parâmetros de solo, a PCA pode identificar quais combinações de parâmetros são mais influentes para uma determinada característica, como a compressibilidade.

DBSCAN (Density-Based Spatial Clustering of Applications with Noise) e Hierarchical Clustering: O DBSCAN é um algoritmo de agrupamento baseado em densidade que é capaz de encontrar clusters de formas arbitrárias em um espaço com ruído. O Hierarchical Clustering constrói uma hierarquia de clusters. Ambos são úteis para classificação de formações geológicas e mapeamentos, onde a identificação de regiões com propriedades distintas é fundamental. Eles podem ser aplicados para segmentar mapas geológicos ou para identificar anomalias em dados de sensoriamento remoto geotécnico, fornecendo insights sobre a estrutura subsuperficial do terreno.

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados na estrutura e funcionamento do cérebro humano, usados para resolver problemas complexos através do aprendizado de padrões em dados. Elas são compostas por unidades de processamento interconectadas, chamadas neurônios artificiais, que trabalham em conjunto para realizar tarefas específicas. RNAs aprendem com exemplos, ajustando seus pesos e parâmetros para realizar tarefas como classificação, previsão e reconhecimento de padrões.

Rede Neural Recorrente (RNN) é um tipo de rede neural artificial projetada para processar dados sequenciais, como texto ou séries temporais. Diferente das redes neurais tradicionais, as RNNs possuem uma "memória" que permite levar em consideração informações de passos anteriores na sequência ao processar a entrada atual.

Em uma RNN, a saída de um passo é usada como entrada para o próximo passo, criando um fluxo de informações que se propaga através da rede. Essa estrutura permite que a rede "lembre-se" de informações passadas e as utilize para entender o contexto e fazer previsões mais precisas.

XGBoost (eXtreme Gradient Boosting) é um algoritmo de aprendizado de máquina popular e altamente eficiente, amplamente utilizado em competições de ciência de dados e aplicações do mundo real. Ele se destaca por ser uma implementação otimizada do Gradient Boosting, uma técnica que constrói um modelo preditivo de forma aditiva, combinando as previsões de vários modelos mais fracos, geralmente árvores de decisão. O XGBoost aprimora o Gradient Boosting com otimizações significativas de software e hardware, como paralelização, poda de árvores inteligentes e manuseio de dados ausentes, resultando em um desempenho superior em termos de velocidade e precisão para uma vasta gama de problemas de regressão e classificação.

WTMM, ou Wavelet Transform Modulus Maxima, é uma técnica utilizada na análise de sinais para identificar e caracterizar singularidades, como pontos de descontinuidade ou mudanças abruptas, em dados. Ela se baseia na **Transformada Wavelet**, que decompõe um sinal em diferentes escalas, revelando informações sobre sua frequência e localização no tempo. Ao analisar os **máximos do módulo** dos coeficientes da transformada wavelet em várias escalas, o WTMM permite pinpointar a localização dessas singularidades e, em alguns casos, determinar sua natureza e intensidade, tornando-se uma ferramenta valiosa em áreas como processamento de imagens, análise de turbulência e detecção de bordas.

3 APLICABILIDADE NA GEOTECNIA

A integração de IA e AM na engenharia geotécnica tem transformado a maneira como os profissionais abordam desafios complexos, oferecendo soluções mais eficientes e precisas. A capacidade de processar

grandes volumes de dados e identificar padrões ocultos permite avanços significativos em diversas áreas (ENTERAZI *et al.*, 2024).

3.1 Estabilidade de Taludes

A análise de estabilidade de taludes é uma preocupação geotécnica constante, especialmente em regiões montanhosas, encostas naturais e cortes de estradas. Modelos de aprendizado supervisionado, como Máquinas de Vetores de Suporte (SVM) e árvores de decisão, têm sido eficazmente utilizados para prever fatores de segurança de taludes. Ao serem treinados com dados históricos de taludes (geometria, tipo de solo, propriedades de resistência, condições de água e ocorrência de deslizamentos), esses modelos podem aprender a identificar as condições que levam à instabilidade.

A acurácia desses modelos de IA, quando bem calibrados, pode ser superior aos métodos clássicos determinísticos, que muitas vezes dependem de simplificações e premissas mais rígidas. Um modelo de SVM, por exemplo, pode ser treinado para classificar um talude como "estável" ou "instável" com base em um conjunto de variáveis de entrada, fornecendo uma avaliação de risco mais abrangente e em tempo real, especialmente quando integrado a sistemas de monitoramento. Isso permite que engenheiros tomem decisões mais informadas sobre a necessidade de medidas de estabilização ou monitoramento contínuo.

3.2 Predição de Propriedades Físico-Mecânicas do Solo

A previsão de propriedades físico-mecânicas do solo é uma das aplicações mais fundamentais da IA na geotecnia. Métodos tradicionais para determinar propriedades como coesão, ângulo de atrito, permeabilidade e índice de compressão geralmente envolvem ensaios laboratoriais demorados e dispendiosos. Algoritmos de AM permitem estimar essas propriedades a partir de dados de campo ou ensaios indiretos, agilizando o processo e reduzindo custos.

Além disso, a aplicação de AM pode auxiliar na estimativa de propriedades como a permeabilidade, utilizando dados como granulometria, índice de vazios e limites de Atterberg, o que é crucial para projetos de drenagem e análise de fluxo em solos.

3.3 Estimativa de Capacidade de Carga

A determinação da capacidade de carga de fundações é um aspecto crítico do projeto de qualquer estrutura civil. A IA pode desempenhar um papel significativo na estimativa da capacidade de carga de fundações superficiais e profundas, especialmente em situações onde os dados diretos de campo são limitados ou inexistentes. Por meio de técnicas de inferência estatística e modelos preditivos baseados em AM, é possível correlacionar dados disponíveis (por exemplo, de ensaios de SPT, CPT ou dados geológicos) com a capacidade de carga esperada.

Por exemplo, redes neurais podem ser treinadas para prever a capacidade de carga de estacas com base em suas dimensões, profundidade de instalação e propriedades do solo obtidas em ensaios geotécnicos. Isso é particularmente útil para projetos em locais com variabilidade de solo significativa ou para a fase de pré-dimensionamento, onde um grande número de alternativas precisa ser rapidamente avaliado. A capacidade de extrapolar e interpolar a partir de dados existentes com a ajuda da IA acelera o processo de projeto e reduz a incerteza associada à estimativa da capacidade de carga.

3.4 Identificação de Litotipias e Classificação de Solos

A classificação e identificação de litotipias são passos fundamentais em qualquer investigação geotécnica. Modelos de agrupamento (clustering), como K-means e PCA, são amplamente utilizados para identificar grupos homogêneos de solos em investigações geotécnicas. Esses algoritmos podem processar grandes volumes de dados de ensaios (granulometria, limites de Atterberg, índices de vazios) e de campo (perfis de sondagem, resultados de ensaios *in situ*) para agrupar solos com características semelhantes.

O estudo de Wang *et al.* (2023) demonstrou o uso da metrologia associada ao agrupamento de perfis geotécnicos, evidenciando como o K-means pode ser aplicado para classificar e caracterizar perfis geológicos e geotécnicos de forma inovadora. Isso permite a criação de modelos de subsuperfície mais

precisos e confiáveis, auxiliando no mapeamento de unidades geológicas e na delimitação de zonas com comportamentos geotécnicos similares, o que é essencial para o projeto e execução de obras civis.

4 ESTUDO DE CASOS EM ENSAIOS CPTu

Foram reunidos exemplos de aplicação destes conceitos de uso de IA e AM para ensaios CPTu. A tabela 1 apresenta um compilado de estudos recentes (2019-2024) que aplicam técnicas de aprendizado de máquina e análise de dados em geotecnia.

Tabela 1. Estudos recentes que aplicam técnicas de aprendizado de máquina e análise de dados em geotecnia.

Autores e Ano	Tipo de estrutura / estudo de caso	Análise	Ferramentas de análise	Resultados da Análise	Observações
Nierwinski <i>et. al.</i> (2019)	Barragens de rejeito, Brasil	Agrupamento para Classificação de perfis geotécnicos	K-means	Classificação de perfis geotécnicos	
Wu <i>et. al.</i> (2021)	Solos gerais da Nova Zelândia	Rede de regressão neural	Máximos do Módulo da Transformada Wavelet (WTMM)	Classificação de perfis geotécnicos	
Pinto <i>et. al.</i> (2022)	Barragem de rejeito de bauxita	Cálculo de parâmetros (resistências, pressões)	Previsão por meio de RNAs	q_c (resist. de ponta), u_2 (poropressão)	Melhor que método baseado em N_{kt} (cone)
Nierwinski <i>et. al.</i> (2023)	Brasil, EUA, Austrália, entre outros	Estimativa de peso específico	Kmeans, regressão e RNN	γ (peso específico)	Aceitável, visto que atualmente é empírico
Phu <i>et. al.</i> (2023)	Ginásio Phu Tho, Ho Chi Minh, Vietnã	Agrupamento q_t (resistência ponta corrigida) e R_f (razão de atrito)	Máquinas de Vetores de Suporte	q_c (resist. de ponta), f_s (atrito lateral), u_2 (poropressão)	Kmeans não foi promissor
Entazari <i>et. al.</i> (2024)	EUA, Canadá, Chile e outros	Árvores de decisão com gradiente de aceleração	XGBoost	V_s (veloc. das ondas de cisalh.)	
Zhang <i>et. al.</i> (2024)	Metrô de Shanghai, China	Agrupamento para Classificação de perfis geotécnicos	K-means, Processo Gaussiano e BIRCH	f_s (atrito lateral)	

Observa-se uma variedade de tipos de estruturas e estudos de caso, desde barragens de rejeito (Nierwinski *et al.*, 2019; Pinto *et al.*, 2022) e solos gerais (WU *et al.*, 2021) até grandes projetos de infraestrutura como o metrô de Xangai (ZHANG *et al.*, 2024) e ginásios (PHU *et al.*, 2023).

As análises são diversas, incluindo agrupamento para classificação de perfis geotécnicos (NIERWINSKI *et al.*, 2019; ZHANG *et al.*, 2024), redes de regressão neural (WU *et al.*, 2021), estimativa de peso específico (NIERWINSKI *et al.*, 2023) e cálculo de parâmetros de resistência (PINTO *et al.*, 2022). As ferramentas de análise empregadas são predominantemente algoritmos de aprendizado de máquina como K-means, regressão, Redes Neurais Artificiais (RNAs), Máquinas de Vetores de Suporte e XGBoost, evidenciando a crescente adoção dessas metodologias na área.

4.1 Resultados

Os estudos indicam bons ganhos de desempenho quando pipelines supervisionados combinam classificação por ML, detecção de limites e interpolação espacial. Em CPTu, os resultados alcançam acurácias >90% na identificação de segmentos e superou gráficos SBTn na validação cruzada em Christchurch e North Island (Nova Zelândia) (WU *et al.*, 2021).

O WTMM modificado corrigiu a tendência do método tradicional de errar limites em transições longas, aproximando os resultados dos furos de sondagens. Para interpolação 3D, a GRNN mostrou acurácia comparável a métodos mais complexos (como CMC) com maior simplicidade operacional, favorecendo a adoção prática em engenharia.

Na predição de propriedades, bases amplas V_s -CPTu mostram melhora quando se agregam coordenadas geográficas e se utiliza SHAP para interpretar a importância de variáveis (profundidade, latitude), ainda que os ganhos sejam regionais e dependentes de cobertura de dados; erros e outliers crescem onde o training é escasso, apontando limites de generalização espacial. Esses achados reforçam que, além de algoritmos robustos, a curadoria de dados (representatividade por sítio/solo) é determinante para desempenho estável fora do conjunto de treinamento (ENTERAZI *et al.*, 2024).

Há divergência entre estudos quanto ao melhor clustering não supervisionado. Com CPT “genérico”, uma comparação sistemática reportou $GMM > BIRCH > k$ -means em diferentes cenários de combinação de classes, sugerindo que distribuições elípticas misturadas se ajustam melhor ao problema do que partições esféricas (ZHANG *et al.*, 2024).

Em rejeitos de mineração com forte variabilidade operacional e drift temporal, séries longas (2005–2024) indicaram maior consistência prática de k -means/MeanShift na captura da variabilidade estratigráfica, enquanto DBSCAN/Affinity tenderam a supersegmentar em presença de ruído e mudanças graduais (NIERWINSKI *et al.*, 2023).

Como direções futuras deste artigo, sugere-se:

- (i) padronizar pipelines reprodutíveis (pré-processamento, features locais como $s^*(Q_m, F_r, B_q)$ e metadados espaciais), reportando ablações e curvas de aprendizado;
- (ii) validar multi-sítio e multi-campanha para estimar drift temporal e robustez fora da amostra, especialmente em ambientes com mudanças operacionais (rejeitos);
- (iii) priorizar modelos interpretáveis ou com explicabilidade post-hoc (e.g., SHAP) em domínios regulados;
- (iv) combinar supervisionado + não supervisionado (rótulos fracos por clustering refinados por RF/GBM), mantendo o WTMM modificado para limites e GRNN para 3D quando a simplicidade operacional for critério de projeto.

5 CONCLUSÃO

A presente revisão confirma que Inteligência Artificial e Aprendizado de Máquina na Interpretação Avançada de Ensaios CPTu constituem um caminho sólido para otimizar práticas geotécnicas, substituindo leituras empíricas isoladas por inferências mais consistentes sobre o subsolo. Em estabilidade de taludes e na predição de propriedades físico-mecânicas, modelos supervisionados (SVM, árvores de decisão e RNAs) ampliam a acurácia quando treinados com séries CPT/CPTu bem curadas; do mesmo modo, fluxos integrados com detecção robusta de limites e interpolação 3D têm mostrado desempenho elevado em estratificação, reforçando o papel do CPTu como eixo de dados para decisões de engenharia. Esses resultados dialogam com evidências recentes de estratificação 1D/3D baseada em CPTu e de predição de V_s a partir de grandes bases, indicando que ganhos consistentes emergem quando os algoritmos incorporam variações locais dos sinais e contexto geoespacial.

No mesmo espírito do título, a interpretação avançada de CPTu também se beneficia de métodos não supervisionados para classificação de litotipias, onde *clustering* (por exemplo k -means, MeanShift) complementa índices tradicionais ao revelar padrões estratigráficos e transições associadas a processos deposicionais; em paralelo, modelos estatísticos e RNAs têm se mostrado eficazes para estimar parâmetros como γ_t e S_u diretamente de registros CPTu, reduzindo tempo e custo de laboratório quando apoiados por validação cruzada adequada. Em síntese, IA/AM não substituem o julgamento geotécnico, mas o qualificam sempre que os dados de CPTu são tratados com rigor metrológico, explicabilidade e validação multi-sítio—condições que sustentam aplicações confiáveis em projeto, monitoramento e gestão do risco.



AGRADECIMENTOS

Agradecemos ao PPGEC – UFSC, ao laboratório GESEG (Grupo de Estudos de Engenharia Geotécnica), bem como a todos os professores pelo apoio prestado nesta pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

- Enterazi, I.; Sharp, J.; Mayne, P. (2024) *A Data-Driven Approach to Predict Shear Wave Velocity from CPTu Measurements: An Update*. Proceedings of the 7th International Conference on Geotechnical and Geophysical Site Characterization Barcelona.
- Garsole, P.; Bokil, S.; Kumar, V.; Pndey, A. Topare, N. (2023) *A review of artificial intelligence methods for predicting gravity dam seepage, challenges and way-out*. AQUA — Water Infrastructure, Ecosystems and Society Vol 72 No 7.
- Nierwinski, H.; Custodio, L.; Barbosa, A.; Pfitscher, R. (2025) *Use of artificial intelligence to obtain stratigraphic profile of tailings dams from CPTu tests*. ASCE Geo-EnvironMeet.
- Nierwinski, H.; Pfitscher, R.; Barra, B.; Menegaz, T. (2023) *A practical approach for soil unit weight estimation using artificial neural networks*. Journal of South American Earth Sciences, 131.
- Phu, T.; Ba, V.; Dai, N. (2023) *Application of Artificial Intelligence to Cluster Soil Behaviour from CPTu Data*. Proceedings of the Third International Conference on Sustainable Civil Engineering and Architecture.
- Pinto, G. H. S.; Brandão, H. A.; Santos, T. B. (2022) *Aplicação do Algoritmo de Redes Neurais na Avaliação da Resistência Não Drenada de Resíduo de Bauxita*. Revista Brasileira de Engenharia de Barragens.
- Wang, L.; WU, C., Yang, Z.; Wang, L. (2022). *Deep learning methods for time-dependent reliability analysis of reservoir slopes in spatially variable soils*. Computers and Geotechnics, Volume 159.
- Wu, S.; Zhang, J.; Wang, R. (2021) *Machine learning method for CPTu based 3D stratification of New Zealand geotechnical database sites*. Advanced Engineering Informatics.
- Zhang, J.; Mao, Z.; Huang, H.; Zhang, D. (2024) *Soil classification based on unsupervised learning using cone penetration test data*. IOP Conf. Ser.: Earth Environ.