

DOI: 10.47094/COBRAMSEG2024/105

Inteligência Artificial e Modelos Pautados em Física na Engenharia Geotécnica: Desafios, Estratégias e a Importância da Interpretabilidade

Luan Carlos de Sena Monteiro Ozelim

Pesquisador Colaborador, Universidade de Brasília, Brasília-DF, Brasil, ozelim@unb.br

Darym Júnior Ferrari de Campos

Engenheiro Geotécnico, Progen S.A., Brasília-DF, Brasil, darymjuni@progen.com.br

José Camapum de Carvalho

Pesquisador Colaborador, Universidade de Brasília, Brasília-DF, Brasil, camapumdecarvalho@gmail.com

André Luís Brasil Cavalcante

Professor, Universidade de Brasília, Brasília-DF, Brasil, abrasil@unb.br

Gilson de Farias Neves Gitirana Junior

Professor, Universidade Federal de Goiás, Goiânia-GO, Brasil, gilsongitirana@ufg.br

RESUMO: A inteligência artificial (IA) está ganhando destaque na modelagem geomecânica de materiais na Engenharia Geotécnica, com redes neurais profundas liderando os métodos orientados a dados. Essas redes se destacam na previsão de estados futuros de sistemas dinâmicos, mas apresentam uma limitação significativa: a falta de interpretabilidade. Modelos baseados em dados focam na previsão e carecem de equações governantes ou interpretação clara das variáveis originais. Existem alternativas para remediar essa questão, mas tais alternativas têm aplicação ainda incipiente na Geotecnia. Este artigo discute estratégias para criar modelos de IA que respeitem princípios físicos, com ênfase em abordagens que permitam a criação de modelos "caixa cinza". Diferente dos modelos teóricos (baseados na física, sem dados) e dos "caixa preta" (baseados em dados, sem compreensão física), os modelos "caixa cinza" combinam conhecimento físico básico com calibração ou complementação por dados. Destaca-se a importância das reflexões de engenharia no uso de modelos de IA e a necessidade de se buscar modelos físicos parcimoniosos e interpretáveis. Assim, a IA deve ser vista como uma aliada na melhoria do entendimento geotécnico, e não como uma substituta aos profissionais que atuam na área.

PALAVRAS-CHAVE: Interpretabilidade, Modelos pautados em física, Redes Neurais.

ABSTRACT: Artificial intelligence (AI) is being increasingly used to perform the geomechanical modeling of materials in Geotechnical Engineering, with deep neural networks leading data-driven methods. These networks are particularly good in predicting future states of dynamic systems but have a significant limitation: lack of interpretability. Data-driven models focus on prediction and lack governing equations or clear interpretation of the original variables. There are alternatives to address this issue, but their application in Geotechnics is still in its early stages. This article discusses strategies to build AI models that respect physical principles, with emphasis on approaches that enable the creation of "gray box" models. Unlike theoretical models (based on physics, without data) and "black box" models (based on data, without a physics background), "gray box" models combine basic physics knowledge with data calibration or supplementation. The importance of combining engineering analyses with AI models is highlighted, emphasizing the need for parsimonious and interpretable AI models. Thus, AI should be seen as an ally in improving geotechnical understanding, not as a substitute for professionals in the field.

KEYWORDS: Interpretability, Physics-informed methods, Neural Networks.

1 INTRODUÇÃO

Montáns *et al.* (2019) indicam que o aprendizado humano depende da observação e vivência do mundo, do qual se coleta dados, às vezes facilmente quantificáveis, às vezes mais qualitativos. Também, a partir da observação, relacionam-se eventos a esses dados colhidos. Por outro lado, é a partir de experiências repetitivas que se pode determinar alguns padrões que relacionam dados e eventos em si. No caso da descoberta científica, esses padrões e relações são formalizados em leis e equações, os dados são formalizados em propriedades e variáveis, e as observações são formalizadas em eventos, que podem ser as próprias ações ou propriedades.

Leis e equações, típicas da ciência, permitem realizar previsões e propiciam a transmissão do procedimento de aprendizagem de forma muito compacta, com o mínimo de informação. No entanto, o processo clássico de aprendizagem em ciência é um processo lento que precisa de muita observação e um grande número de experimentos, por vezes de custo elevado, para descobrir as principais variáveis envolvidas e sua influência no fenômeno que se busca entender e no campo geotécnico tais variáveis são muitas vezes dinâmicas no espaço e no tempo. Esse processo acaba por apresentar algumas questões importantes, como uma quantidade provavelmente enorme de combinações possíveis de variáveis, fazendo com que frequentemente se esqueça variáveis relevantes. Além do mais, a abordagem científica clássica é orientada por hipóteses e, portanto, é tendenciada por elas (Montáns *et al.*, 2019).

Os procedimentos orientados a dados buscam, na medida do possível, uma abordagem implicitamente imparcial para a experiência de aprendizado com base em dados brutos de observações reais. Esses procedimentos têm a vantagem adicional de testar correlações entre diferentes variáveis e observações, aprender sobre padrões imprevistos na natureza e permitir descobrir novas leis científicas ou, ainda, realizar previsões sem a disponibilidade de tais leis (Montáns *et al.*, 2019). Nesse contexto, quando se está tratando de infraestruturas geotécnicas cujo comportamento é complexo e/ou parcialmente explicado por modelos e arranjos numéricos tradicionais, uma abordagem que tem ganhado força é a utilização de técnicas de inteligência artificial (IA) e aprendizagem de máquinas (*machine learning* – ML) capazes de gerar modelos que buscam reproduzir o comportamento do sistema como um todo fundamentado em resultados experimentais ou de monitoramento de campo. Cabe destacar que as técnicas de IA e ML tem origem natural, pois são fruto da inteligência humana.

Conforme indica Ferrari de Campos (2022), a coleção de algoritmos e métodos de mineração de dados desenvolvidos constitui-se como pilar central dos agentes de IA e, embora a IA tenha uma longa história em descobertas científicas, abordagens orientadas a dados podem agora ingerir e processar algoritmos em escala, dado o avanço dos computadores atuais. Nesse contexto, o recente e rápido aumento na disponibilidade de dados de medição de sistemas físicos estimulou o desenvolvimento de muitos métodos baseados em dados para modelagem e previsão de dinâmica. Na vanguarda dos métodos orientados a dados estão as redes neurais profundas (*Deep Neural Networks* - DNNs). As DNNs não apenas alcançam desempenho superior para tarefas como classificação de imagens, mas também têm se mostrado eficazes para previsão de estado futuro de sistemas dinâmicos (Raissi *et al.*, 2019). Uma limitação chave de DNNs, e métodos similares baseados em dados, é a falta de interpretabilidade do modelo resultante: eles são focados na previsão e não fornecem equações governantes ou modelos claramente interpretáveis em termos do conjunto de variáveis original. Assim, o presente artigo se debruça sobre a importância da inclusão de balizadores físicos durante a criação e uso de modelos de inteligência artificial, em especial daqueles que utilizam redes neurais profundas no contexto da Engenharia Geotécnica. Inicialmente, uma breve análise bibliométrica sobre o impacto acadêmico dessa temática é apresentando. Posteriormente, discute-se sobre modelagem no contexto geotécnico e, finalmente, sobre os desafios, estratégias e a importância da interpretabilidade dos modelos pautados em IA.

2 INTERESSE ACADÊMICO: MODELAGEM ORIENTADA A DADOS E PAUTADA EM FÍSICA

Quando se pensa em justificar a importância e abrangência de um dado tema de pesquisa, há dois grandes aspectos que devem ser abordados, quais sejam: importância acadêmica e abrangência prática. Do ponto de vista acadêmico, a importância do estudo de modelos criados a partir de técnicas de inteligência artificial (*artificial intelligence* - AI), aprendizado de máquina (*machine learning* - ML) e aprendizado profundo (*deep learning* - DL) dentro da grande área de Engenharia Civil (4005 *Civil Engineering*) pode ser revelada por uma

simples análise bibliométrica realizada na ferramenta *Dimensions* (<https://www.dimensions.ai/>), para o período de janeiro de 2015 a abril de 2024, usando a busca dentre palavras-chave com o texto “(*machine learning*) AND (*artificial intelligence*) AND (*deep learning*)” e o campo de pesquisa de “(4005 *Civil Engineering*)”. Nessa primeira análise, nota-se um crescente interesse no tema, com um total de 21684 publicações e um total de 260973 citações, o que rende uma média de mais de 12 citações por artigo publicado. Os dados em laranja nas Figuras 1(a) e 1(b) mostram isso.

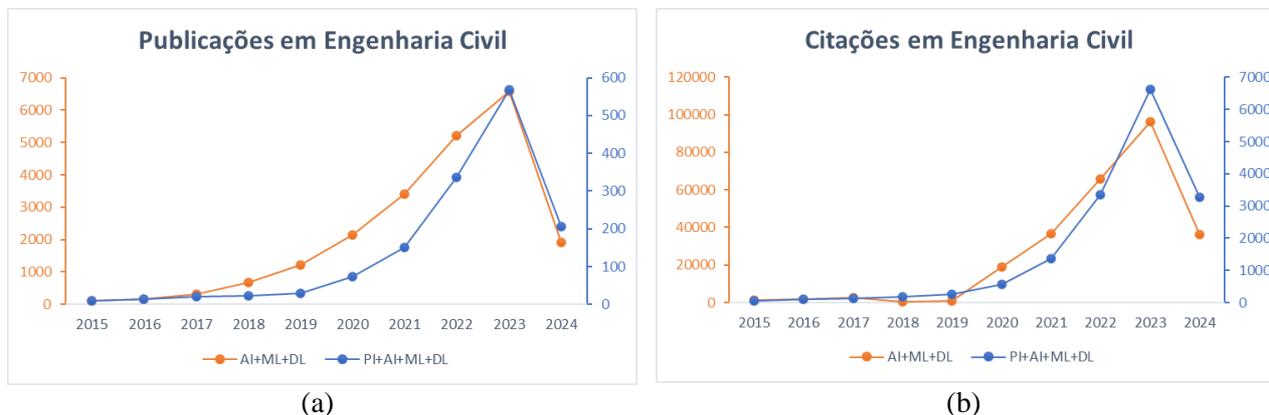


Figura 1. Publicações (a) e citações (b) de artigos publicados na grande área de Engenharia Civil utilizando as palavras-chave indicadas.

Ao considerar o estudo de modelos pautados em física (*physics-informed models - PI*), uma nova análise para o mesmo período revela, ao adicionar a palavra chave “*physics-informed*” à busca, um total de 1430 publicações sobre o tema, com 15909 citações, gerando uma média de mais de 11 citações por artigo publicado. Esse comportamento pode ser visto nos dados marcados em azul nas Figuras 1(a) e 1(b). Nessas figuras, nota-se que a velocidade de crescimento tanto no número de publicações quanto de citações para estudos que consideram modelos pautados em física é maior do que aqueles que não o fazem. Além disso, a partir de 2021 há um crescimento vertiginoso no interesse pelos modelos pautados em física, o que é reflexo da constatação de que modelos puramente baseados em dados trazem senões importantes, principalmente para sua aplicação em situações de campo, e têm grande dificuldade para refletir a variabilidade espacial e temporal das situações fáticas. Esse mesmo fenômeno, de maior interesse em modelos com restrições físicas, pode ser visualizado na Figura 2, em que são mostrados os percentuais de artigos publicados que receberam ao menos uma citação durante o período indicado. Na Figura 2, fica visualmente evidente que o estudo das técnicas de inteligência artificial pautadas em física tem gerado maior interesse a partir de 2021 (o percentual de artigos com citações é maior do que aqueles sem a consideração de restrições físicas).

Destaca-se que além do interesse acadêmico em ultrapassar as fronteiras do conhecimento em um dado tema de pesquisa, há também motivações de ordem prática para o tema de pesquisa em questão. Considerando a não rara grande abrangência dos projetos e obras de infraestrutura geotécnica, quando de uma eventual falha, é possível que diversas pessoas beneficiadas por essa infraestrutura sejam prejudicadas. Dessa forma, garantir a operação sem intercorrências desses elementos é não apenas um desejo, mas sim uma obrigação das diversas entidades públicas e empresas responsáveis por essas estruturas. Importante notar que, mesmo em casos mais simples, em que pequenos deslocamentos não previstos são observados em certas estruturas (túnel, fundação barragem etc.), por vezes é necessário suspender a atividade/ocupação local por dias para uma avaliação mais criteriosa do problema. Essa paralisação é capaz de gerar enormes prejuízos a quem depende desse uso/ocupação. Fica claro, portanto, que dispor de um melhor entendimento do comportamento geomecânico de infraestruturas geotécnicas é fundamental para que se garanta a segurança operacional e para que se minimizem os riscos geotécnicos. Assim, a temática da construção de modelos orientados por dados e aplicados à modelagem de infraestruturas geotécnicas se faz necessária, em especial daqueles que respeitam restrições físicas conhecidas, de maneira a avançar na representatividade que esses modelos apresentam da realidade.




Figura 2. Interesse acadêmico relativo (percentual de artigos com citações) dentro da grande área de Engenharia Civil para as palavras-chave indicadas.

3 MODELAGEM EM ENGENHARIA GEOTÉCNICA

Zhang *et al.* (2023) defendem que os solos e materiais encontrados no âmbito da Engenharia Geotécnica apresentam comportamentos mecânicos complexos devido à sua composição, microestruturas e morfologias complementando se aqui esse entendimento com o fato de serem eles comumente dotados de grande variabilidade espacial e temporal. Inúmeros modelos constitutivos avançados foram propostos na literatura geotécnica para capturar esses comportamentos (Amorosi *et al.*, 2021, Jefferies & Been, 2015, Rouainia & Muir Wood, 2000, Yin *et al.*, 2011). Geralmente, os modelos existentes são baseados em leis teóricas sofisticadas e amplo conhecimento de domínio, o que pode às vezes dificultar a transferência completa do entendimento para a prática dos engenheiros de projeto e, portanto, a adoção pela indústria. A tendência de um número crescente de parâmetros constitutivos também apresenta desafios com a calibração de parâmetros e a convergência computacional quando incorporados em pacotes de modelagem numérica (Zhang *et al.*, 2021). Por essas razões, modelos constitutivos precisos, que sejam simples, interpretáveis e confiáveis, continuam sendo altamente desejáveis.

Nessa linha, Jefferies & Been (2015) argumentam que o tempo e os esforços empreendidos na criação de modelos, particularizados a um projeto em específico, configuram-se como restrições ao emprego de análises numéricas mais abrangentes na prática da Engenharia. Tal fato decorre de que, ao longo do processo de modelagem, os custos com a criação de ferramentas computacionais sob medida (implementação de *solvers* numéricos ou de modelos constitutivos refinados) podem consumir rapidamente o orçamento disponível dentro do projeto, o que faz com que a prática de Engenharia fique basicamente restrita a “plataformas de modelagem” geotécnicas comerciais, como FLAC, PLAXIS ou SIGMA/W. Em alguns casos, plataformas mais gerais como ABAQUS e COMSOL podem acabar também negligenciadas, devido às particularidades que seu uso apresenta.

Uma das maiores questões em utilizar essas plataformas de modelagem é que, em seus pacotes-padrão, por vezes os modelos disponíveis ou sobre ou sub representam as particularidades dos materiais de interesse. Isso faz com que surja a necessidade de criar ou adaptar modelos que sejam capazes de incorporar tais particularidades sem que haja a necessidade de implementações computacionais rebuscadas, processo esse que acaba implicando em ajustes de valores de parâmetros para aproximar uma dada situação real (teste de laboratório ou monitoramento de campo, por exemplo) ao resultado da simulação numérica.

Nesse contexto, a criação de novos modelos aplicados à modelagem geomecânica de infraestruturas geotécnicas tem ocorrido. Em especial, a modelagem baseada em IA e ML, orientada por dados, surgiu como uma ferramenta promissora para complementar as técnicas existentes de modelagem constitutiva de solos (Basheer, 2000, Karapiperis *et al.*, 2021, Wang & Sun, 2018, Zhang *et al.*, 2020). Essa abordagem envolve aprender relações tensão-deformação diretamente dos dados, ou seja, sem nenhum conhecimento/pressupostos de domínio. Esses modelos podem ser capazes de proporcionar modelagens mais orientadas a dados que, em última análise, podem melhorar o entendimento que se tem a respeito dos materiais e estruturas envolvidos. Fica claro, portanto, que a evolução do uso de plataformas de modelagem tradicionais passa pelo processo de criação de modelos mais gerais a partir de IA e ML.

4 DESAFIOS NO USO DE MODELOS CRIADOS A PARTIR DE DNNs

Para que se possa criar modelos a partir de DNNs, esse tipo de abordagem geralmente requer a calibração a priori dos algoritmos a partir de dados considerados como representativos do comportamento do material (He *et al.*, 2021). Smyrniou (2018) avaliou quais técnicas de DNNs podem ajudar na modelagem do comportamento de tensão e deformação de solos. Para aquela autora, a rede funcionaria como uma caixa preta (sem possibilidade de interpretação para a rede em si). Assim, Smyrniou (2018) mostrou que a rede é bem sucedida ao reproduzir uma matriz elástica linear completa. No caso de um modelo que previa uma lei de endurecimento, a rede analisada não apresentou bons resultados.

Embora essa abordagem simplifique muito o processo de modelagem, a falta de confiabilidade na previsão, especialmente fora dos dados de calibração, é amplamente documentada (Linka *et al.*, 2021, Xu *et al.*, 2021). A dependência típica de grandes volumes de dados pode se tornar proibitiva para aplicações geotécnicas, dada a custosa aquisição de dados de alta qualidade. Assim, por melhores que sejam os resultados dos modelos indicados, nota-se que a falta de balizadores físicos compromete a generalização dos resultados para situações aplicadas da Engenharia. Quando as situações de campo são consideradas, os erros tendem a aumentar grandemente, pois a capacidade extrapolativa desses modelos, que foram calibrados puramente a partir de um contexto de aprendizagem estatística, são bastante reduzidas. Surge, assim, a necessidade de discutir como incorporar a física no processo de construção de modelos orientados a dados.

5 MODELOS QUE RESPEITAM A FÍSICA DOS FENÔMENOS

Conforme reforçam He *et al.* (2021), a computação orientada a dados com restrições físicas é um paradigma computacional emergente que permite a simulação de materiais complexos diretamente de bancos de dados do comportamento desses materiais, ignorando a construção clássica do modelo constitutivo. De maneira geral, há uma diversidade de estratégias que podem ser empregadas para a criação desses modelos balizados. Em especial, há arquiteturas que permitem desenvolver estratégias de modelagem “caixa preta” e “caixa cinza” para sistemas complexos onde a física é apenas parcialmente conhecida. Em contraste com os modelos teóricos (totalmente determinados a partir da física, sem necessidade de dados) e de “caixa preta” (totalmente determinados a partir de dados, sem necessidade de compreensão física), um modelo de “caixa cinza” é um modelo que emprega alguma física ou compreensão básica, mas que ainda precisa ser calibrado ou completado com os dados. Assim, a abordagem “caixa cinza” se torna bastante interessante ao aliar as melhores características de ambos os modelos (“caixas preta” e puramente teóricos).

Além disso, a arquitetura de um algoritmo de IA não apenas permite impor restrições físicas, ou física pré-definida, mas também pode descobrir restrições físicas que precisam ser incorporadas, ou seja, pode-se tanto restringir o aprendizado quanto aprender restrições (Loiseau & Brunton, 2018; Kaiser *et al.*, 2018). Assim, se corretamente orientados, algoritmos de “caixa cinza” se tornam valiosos aliados na descoberta de novas relações antes não vislumbradas. Dessa forma, não apenas modelos físicos parcimoniosos e interpretáveis podem ser descobertos como resultado direto de tais estratégias, mas também podem ser descobertos *insights* críticos, como leis de conservação e restrições físicas. Essas inovações têm o potencial de descobrir modelos generalizáveis que podem ser modificados para lidar com física multiescala, sistemas ruidosos e dados limitados (Montáns *et al.*, 2019).

6 ESTRATÉGIAS PARA CONSTRUÇÃO DE MODELOS QUE RESPEITAM A FÍSICA

De maneira geral, uma primeira abordagem possível é aquela que utiliza regressão simbólica para identificar diretamente a estrutura de um sistema dinâmico não linear a partir de dados (Schmidt & Lipson, 2009). Isso funciona notavelmente bem para descobrir modelos físicos interpretáveis, mas a regressão simbólica é computacionalmente cara e pode ser difícil de dimensionar para grandes problemas (Montáns *et al.*, 2019). Alternativas mais rebuscadas, como aquela de He *et al.* (2021), exploram técnicas de aprendizado profundo com uma arquitetura de rede neural de *autoencoder* capaz de aprender a representação de baixa dimensão subjacente do banco de dados de materiais por eles estudados. He *et al.* (2021) ainda utilizam um esquema de interpolação de preservação de convexidade para garantir a estabilidade numérica e variedade constitutiva representativa.

Quanto à previsão de comportamentos complexos de materiais geotécnicos, a combinação de conhecimento prévio com modelagem orientada por dados representa o estado da arte para aplicações práticas

de IA e ML (Zhang *et al.*, 2023). Essa abordagem envolve a incorporação de empirismo ou leis teóricas conhecidas como informações prévias dentro do framework orientado por dados (Cuomo *et al.*, 2022, Liu & Wang, 2019, Raissi *et al.*, 2019, Sun *et al.*, 2020). A operação mais comum é incorporar leis físicas subjacentes, como balanço e funções potenciais, nas funções de perda de IA/ML, de modo que as previsões sejam restritas a valores admissíveis na prática profissional (Flaschela *et al.*, 2021, Vlassis & Sun, 2021). Pesquisas recentes também exploraram frameworks orientados por dados personalizados para incluir conhecimento prévio de domínio (Bonatti & Mohr, 2022), que comumente assumem a forma de uma estrutura hierárquica envolvendo submodelos conectados por leis teóricas, como a termodinâmica (Linka *et al.*, 2021, Masi *et al.*, 2021). Em tais casos, as 'sub-previsões' são otimizadas internamente para alcançar previsões de saída confiáveis. Outra estratégia é reescrever os pares de entrada-saída para incorporar informações prévias como restrições adicionais (Fuhg & Bouklas, 2022, Klein *et al.*, 2022).

Wang (2019) discute a aplicação do aprendizado de máquina na geração de modelos constitutivos substitutos precisos e confiáveis para geomateriais com multiescala e multifísica, mostrando que esse processo não é trivial. Para tanto, aquele autor propõe um processo de modelagem integrado para o desenho automático, treinamento, validação e “falsificação” de modelos constitutivos, ou “metamodelagem”. Em especial, para permitir que a IA assuma as tarefas de tentativa e erro no processo de modelagem constitutiva, Wang (2019) apresenta uma nova estrutura de “metamodelagem” que emprega teoria de grafos e aprendizado de reforço profundo para gerar modelos com aprendizado de máquina precisos, compatíveis com a física e interpretáveis. Ainda, para superar o obstáculo de informações limitadas em geomecânica, Wang (2019) descreve como aumentar a eficiência na utilização de dados experimentais por uma estrutura de metamodelagem cooperativa multiagente, fornecendo orientação na geração de banco de dados e modelagem constitutiva simultânea.

Zhang *et al.* (2021) indicam que outra opção que tem ganhado força é trazer conhecimentos pré-estabelecidos por meio de treino a partir de dados sintéticos obtidos de modelos constitutivos teóricos, haja vista ser possível a criação de um suprimento teoricamente ilimitado de dados utilizando simulações numéricas. Nesse sentido, a literatura sugere que modelos orientados por dados podem ser inicialmente desenvolvidos usando conjuntos de dados sintéticos para estabelecer um quadro geral, que pode posteriormente ser aplicado a conjuntos de dados experimentais para aprimorar a robustez do modelo e auxiliar na descoberta de potenciais mecanismos de comportamento do solo (Zhang *et al.*, 2021). Ao calibrar modelos constitutivos em conjuntos de dados sintéticos, o impacto de erros experimentais e de medição na capacidade de mapeamento dos algoritmos de aprendizado de máquina pode ser eliminado (Zhang *et al.*, 2020). Portanto, a criação de conjuntos de dados sintéticos grandes e confiáveis é um passo crucial na construção de modelos constitutivos orientados por dados.

Para materiais de modelagem mais complexa, como é o caso de rejeitos de mineração, estudar essa modelagem constitutiva a partir de dados pode ser uma boa solução, que alia precisão a tempos computacionais pequenos. Recentemente, Ozelim *et al.* (2023) enfrentaram os desafios associados à quantidade e complexidade de conjuntos de dados sintéticos necessários para modelagem constitutiva não linear de solos, em especial de situações de liquefação de solos. Dessa maneira, a partir de bancos de dados abrangentes como aquele apresentado por Ozelim *et al.* (2023), torna-se possível criar metamodelos baseados em técnicas de inteligência artificial, especialmente aprendizado de máquina e aprendizado profundo, capazes de fornecer modelos precisos e computacionalmente mais acessíveis.

7 CONCLUSÕES

É inquestionável que as ferramentas de inteligência artificial podem ser poderosas aliadas na busca por um melhor entendimento do comportamento geotécnico dos solos. No entanto, o uso indiscriminado desses algoritmos, que são puramente pautados em dados e em otimização de relações estatísticas, pode levar a graves problemas quando da aplicação a situações reais sem que ocorra uma criteriosa avaliação por parte de profissionais qualificados para tal. Como demonstrado, esses modelos podem levar à falta de confiabilidade na previsão, especialmente fora dos dados de calibração. Nesse sentido, uma série de ferramentas tem sido desenvolvida para agregar aos modelos de IA uma série de preceitos físicos conhecidos sobre os problemas em estudo, possibilitando assim a criação dos modelos pautados em física. Esses modelos, além de mitigarem a dependência típica de grandes volumes de dados para calibração (que podem se tornar proibitivos para aplicações geotécnicas, dada a custosa e demorada aquisição de dados de alta qualidade), também proporcionam melhores generalizações para situações práticas. Importante destacar que, mesmo para modelos

pautados em física, seus resultados devem ser interpretados por um profissional qualificado, sendo crucial que a decisão final parta desse profissional. IA e ML são ferramentas a serem usadas como auxiliares na tomada de decisão, não como substitutas de profissionais capacitados para tal.

Dessa forma, o presente artigo buscou contextualizar o uso de IA, em particular de redes neurais profundas, na criação de modelos úteis à Engenharia Geotécnica. Para tanto, uma vasta revisão da literatura apresentou os desafios, estratégias de implementação e a importância de se considerar modelos interpretáveis e pautados em física conhecida. Assim, não apenas modelos físicos parcimoniosos e interpretáveis podem ser desenvolvidos como resultado direto de tais estratégias, mas também podem ser descobertos *insights* críticos, como leis de conservação e restrições físicas. Essas inovações têm o potencial de desenvolver modelos generalizáveis aptos a tratar física multiescala, sistemas ruidosos e dados limitados.

REFERÊNCIAS BIBLIOGRÁFICAS

- Amorosi, A., Rollo, F., Dafalias, Y.F. (2021). Relating elastic and plastic fabric anisotropy of clays. *Geotechnique*, 71 (7), p.583–593.
- Basheer, I.A. (2000) Selection of methodology for neural network modeling of constitutive hystereses behavior of soils. *Comput.-Aided Civ. Inf.*, 15, p.440–458.
- Bonatti, C.; Mohr, D. (2022) On the importance of self-consistency in recurrent neural network models representing elasto-plastic solids. *J. Mech. Phys. Solids.*, 158, p.104697.
- Cuomo, S.; Di Cola, V.S.; Giampaolo, F.; Rozza, G.; Raissi, M.; Piccialli, F. (2022) Scientific machine learning through physics-informed neural networks: where we are and what's next. *J. Sci. Comput.*, 92, p.88.
- Ferrari de Campos, D.J. (2022) *Big data e inteligência artificial aplicados a fundações*. Tese (Doutorado em Geotecnia) — Universidade de Brasília, Brasília, 143p.
- Flaschela, M.; Kumar, S.; De Lorenzis, L. (2021) Unsupervised discovery of interpretable hyperelastic constitutive laws. *Comput. Meth. Appl. Mech. Eng.*, 381, p.113852.
- Fuhg, J.N.; Bouklas, N. (2022) On physics-informed data-driven isotropic and anisotropic constitutive models through probabilistic machine learning and space-filling sampling. *Comput. Meth. Appl. Mech. Eng.*, 394, p.114915.
- He, X.; He, Q.; Chen, J.-S. (2021) Deep autoencoders for physics-constrained data-driven nonlinear materials modeling. *Computer Methods in Applied Mechanics and Engineering*, 385, p.114034.
- Jefferies, M.; Been, K. (2015) *Soil liquefaction: a critical state approach*. CRC press, New York, USA, 712 p.
- Kaiser, K.; Kutz, J.N.; Brunton, S.L. (2018) Discovering conservation laws from data for control, in: 57th IEEE Conference on Decision and Control, Miami Beach, FL, Dec 17–19, 2018, pp. 6415–6421.
- Karapiperis, K.; Stainier, L.; Ortiz, M.; Andrade, J.E. (2021) Data-Driven multiscale modeling in mechanics. *J. Mech. Phys. Solids*, 147, p.104239.
- Klein, D.K.; Fernandez, M.; Martin, R.J.; Neff, P.; Weeger, O. (2022) Polyconvex anisotropic hyperelasticity with neural networks. *J. Mech. Phys. Solids*, 159, p.104703.
- Linka, K.; Hillgartner, M.; Abdolazizi, K.P.; Aydin, R.C.; Itskov, M.; Cyron, C.J. (2021) Constitutive artificial neural networks: A fast and general approach to predictive data-driven constitutive modeling by deep learning. *J. Comput. Phys.*, 429, p.110010.
- Liu, D.; Wang, Y. (2019) Multi-fidelity physics-constrained neural network and its application in materials modeling. *J. Mech. Des.*, 141 (12), p.121403.
- Loiseau, J.-C.; Brunton, S.L. (2018) Constrained sparse Galerkin regression, *J. Fluid Mech.*, 838 p.42–67
- Montáns, F. J.; Chinesta, F.; Gómez-Bombarelli, R.; Kutz, J. N. (2019) Data-driven modeling and learning in science and engineering. *Comptes Rendus Mécanique*, 347(11), p.845-855.

- Masi, F.; Stefanou, I.; Vannucci, P.; Maffi-Berthier, V. (2021) Thermodynamics-based artificial neural networks for constitutive modeling. *J. Mech. Phys. Solids*, 147, p.104277.
- Ozelim, L. C. S. M.; Casagrande, M. D. T.; Cavalcante, A. L. B. (2023) NorSand4AI: A Comprehensive Triaxial Test Simulation Database for NorSand Constitutive Model Materials, *Geoscientific Model Development – GMD*, aceito para publicação.
- Raissi, M.; Perdikaris, P.; Karniadakis, G.E. (2019) Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *J. Comput. Phys.*, 378, p.686–707.
- Rouainia, M.; Muir Wood, D. (2000). A kinematic hardening constitutive model for natural clays with loss of structure. *Géotechnique*, 50 (2), p.153–164.
- Schmidt, M.; Lipson, H. (2009) Distilling free-form natural laws from experimental data, *Science*, 324 (5923) p.81–85.
- Smyrniou, E. (2018) *Soil Constitutive Modelling Using Neural Networks*. Dissertação de Mestrado, Department of Geo-Engineering, Delft University of Technology, Delft, Netherlands, 94p.
- Sun, L.; Gao, H.; Pan, S.; Wang, J.-X. (2020) Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data. *Comput. Meth. Appl. Mech. Eng.*, 361, p.112732.
- Vlassis, N.N.; Sun, W. (2021) Sobolev training of thermodynamic-informed neural networks for interpretable elasto-plasticity models with level set hardening. *Comput. Meth. Appl. Mech. Eng.*, 377, p.113695.
- Wang, K. (2019) From multiscale modeling to metamodeling of geomechanics problems. Tese de Doutorado, Graduate School of Arts and Sciences, Civil Engineering and Engineering Mechanics, Columbia University, Nova Iorque, NY, EUA. 291p.
- Wang, K.; Sun, W. (2018) A multiscale multi-permeability poroplasticity model linked by recursive homogenizations and deep learning, *Comput. Methods Appl. Mech. Engrg.*, 334, p.337–380.
- Xu, K.; Huang, D.Z.; Darve, E. (2021) Learning constitutive relations using symmetric positive definite neural networks. *J. Comput. Phys.*, 428, p.110072
- Yin, Z.-Y.; Karstunen, M.; Chang, C.S.; Koskinen, M.; Lojander, M. (2011) Modeling time-dependent behavior of soft sensitive clay. *J. Geotech. Geoenviron. Eng.*, 137 (11), p.1103–1113.
- Zhang, P.; Yin, Z.-Y.; Jin, Y.-F.; Ye, G.-L. (2020) An AI-based model for describing cyclic characteristics of granular materials, *Int. J. Numer. Anal. Methods Geomech*, 44, p.1315–1335.
- Zhang, P.; Yin, Z.-Y.; Jin, Y.-F. (2021) State-of-the-Art Review of Machine Learning Applications in Constitutive Modeling of Soils, *Archives of Computational Methods in Engineering*, 28, p.3661–3686.
- Zhang, P.; Yin, Z.-Y.; Sheil, B. (2023) Interpretable data-driven constitutive modelling of soils with sparse data, *Computers and Geotechnics*, 160, p.105511.