



APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA EDUCAÇÃO EM ENGENHARIA: DA TEORIA À PRÁTICA COM A CRIAÇÃO DE UMA WEBAPP PARA HOMOGENEIZAÇÃO DE MATERIAIS

DOI: 10.37702/2175-957X.COBENGE.2025.6232

Autores: ELIÉDSON RAFAEL DE CARVALHO, JULIANA LIRA BRITO DE CARVALHO, JESIMIEL PINHEIRO CAVALCANTE, RODRIGO MERO SARMENTO DA SILVA

Resumo: A integração da Inteligência Artificial (IA) na educação em engenharia tem revolucionado o processo de ensino aprendizagem, oferecendo novas oportunidades e desafios. Este trabalho tem como objetivo relatar a experiência de desenvolvimento de uma webapp interativa para a homogeneização de materiais, utilizando o suporte de IA para a criação e adaptação dos códigos. Os procedimentos metodológicos foram divididos em etapas que englobaram a definição do problema, a colaboração com a IA para desenvolvimento de códigos em ambiente de programação (MATLAB), a transição e construção da webapp em ambiente web (HTML/JavaScript), a validação da ferramenta desenvolvida e, por fim, a análise dos resultados. Os principais resultados demonstram a acurácia da webapp na previsão das propriedades efetivas e evidenciam o potencial da IA como facilitadora técnica e didática, otimizando a construção de ferramentas computacionais e aprofundando o aprendizado nos conceitos de engenharia.

Palavras-chave: Inteligência Artificial, Micromecânica, Webapp

APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA EDUCAÇÃO EM ENGENHARIA: DA TEORIA À PRÁTICA COM A CRIAÇÃO DE UMA WEBAPP PARA HOMOGENEIZAÇÃO DE MATERIAIS

1 INTRODUÇÃO

A educação em engenharia, historicamente desafiada pela complexidade de seus conceitos e pela necessidade de desenvolvimento de habilidades específicas, tem buscado constantemente inovações pedagógicas para aprimorar o processo de ensino-aprendizagem. Estudantes da área, ao se depararem com modelos microscópicos e macroscópicos, que muitas vezes extrapolam a percepção sensorial humana e demandam maior abstração ou o uso de aparatos específicos, enfrentam dificuldades consideráveis na compreensão de determinados conteúdos (Carvalho et al., 2021). A análise de elementos estruturais, por exemplo, é de fundamental importância na formação do engenheiro civil, mas as abordagens tradicionais, muitas vezes, limitam a diversificação e a profundidade na conceituação.

Apesar dessas dificuldades, a inserção de novas tecnologias da informação e comunicação (TICs), combinadas com metodologias de ensino-aprendizagem contemporâneas, tem contribuído significativamente para o aumento da experiência de ensino e a melhoria da qualidade da educação. Nesse contexto, em seus estudos Carvalho et al. (2024) mostraram que aplicativos móveis e outras ferramentas digitais surgem como soluções promissoras, oferecendo vantagens como maior agilidade na resolução de problemas, interatividade aprimorada e recursos gráficos mais precisos, o que pode reduzir as simplificações de cálculo. Chakraborty (2024) revela que o uso dessas tecnologias cria a oportunidade de ressignificar o ensino de conteúdos de engenharia, ao permitir a elaboração de cenários que proporcionam um processo mais imersivo e próximo da realidade prática.

Recentemente, a Inteligência Artificial (IA), e em particular os Modelos de Linguagem Grandes (LLMs), emergiu como um catalisador para a inovação educacional. Essa tecnologia tem transformado vários aspectos da educação, impulsionando avanços na tutoria automatizada, avaliação e geração de conteúdo (Kamalov et al., 2025). A IA Generativa, por exemplo, oferece ferramentas e metodologias que redefinem como o conhecimento é criado, disseminado e consumido, com destaque para a otimização de ambientes de aprendizado dialogados (Hu et al., 2025).

A aplicação da IA na educação em engenharia transcende a mera automação, promovendo uma interação mais dinâmica e personalizada com o conteúdo. A capacidade de LLMs se assemelharem à cognição humana abre novas oportunidades para o aprendizado personalizado, mas também levanta questões sobre o alinhamento dessas inovações com práticas pedagógicas sólidas (Hu et al., 2025). Contudo, a IA, se aproveitada adequadamente, pode fortalecer a inclusão, melhorar a qualidade do aprendizado e expandir o acesso ao conhecimento, desde que haja estruturas de implementação éticas e inclusivas (Fitas, 2025).

A micromecânica de materiais heterogêneos é uma área que, embora fundamental para o entendimento do comportamento de compósitos, frequentemente envolve cálculos complexos e a compreensão de conceitos abstratos, como as propriedades efetivas mecânicas ou térmicas (Qu e Cherkaoui, 2006). A habilidade de simular e prever o comportamento desses materiais é crucial para engenheiros, mas o acesso a ferramentas que facilitem esse processo pode ser limitado ou demandar conhecimentos avançados em programação.

Neste contexto, a colaboração com a Inteligência Artificial pode ser um diferencial para superar essas barreiras. A experiência de desenvolver um programa interativo em HTML/JavaScript, que simula o cálculo de propriedades efetivas utilizando métodos de

implementação dos modelos da micromecânica de materiais heterogêneos, mesmo com conhecimento básico em programação, demonstra como a IA pode democratizar o acesso a ferramentas computacionais complexas. Este processo não apenas agiliza o desenvolvimento de soluções técnicas, mas também atua como um recurso didático valioso, tornando conceitos complexos mais acessíveis e estimulando o aprendizado prático.

Diante do exposto, este trabalho tem como objetivo relatar a experiência de desenvolvimento de uma *webapp* interativa, denominada "Calculadora de Propriedades Efetivas", para a homogeneização de materiais, utilizando o suporte de Inteligência Artificial para a criação e adaptação dos códigos. Adicionalmente, busca-se validar os resultados obtidos por essa ferramenta em comparação com dados da literatura, demonstrando a aplicabilidade prática da IA no ensino de engenharia e seu potencial para otimizar o aprendizado em micromecânica de materiais.

2 REFERENCIAL TEÓRICO

O referencial teórico deste trabalho aborda os conceitos fundamentais da homogeneização de materiais compósitos e o papel crescente da Inteligência Artificial, especificamente dos Grandes Modelos de Linguagem (LLMs), no contexto educacional.

2.1 Homogeneização de Materiais Compósitos

A análise micromecânica de materiais compósitos consiste no estudo das características de cada material constituinte e suas interações, com o intuito de estimar valores médios para as propriedades do compósito (Kaw, 2006). Essa abordagem permite, ainda, verificar os modos de falha, possibilitando a determinação de critérios de resistência para os compósitos. As propriedades mecânicas efetivas são calculadas com base no conhecimento prévio das propriedades individuais das fases constituintes, bem como suas proporções na construção do compósito (Carvalho; Cavalcante; Marques, 2020).

A micromecânica não se restringe ao cálculo das propriedades mecânicas, incluindo também propriedades de expansão térmica, expansão por umidade e condutividade térmica. Segundo Jones (1999), a modelagem micromecânica pode ser considerada extremamente ampla, partindo de conceitos tecnicamente simples até métodos bem mais sofisticados baseados na Teoria da Elasticidade.

Entre os diversos modelos micromecânicos disponíveis para a homogeneização, o modelo de Mori-Tanaka e o Esquema Diferencial são amplamente utilizados para avaliar as propriedades elásticas efetivas, especialmente para inclusões elipsoidais.

Modelo de Mori-Tanaka: Fundamentos e Aplicações

O Método de Mori-Tanaka, que serve como base para o desenvolvimento da maioria dos modelos da micromecânica fundamentados na teoria dos campos médios, difere dos métodos clássicos por levar em consideração o efeito da interação entre as inclusões. Segundo Qu e Cherkaoui (2006), o modelo de Mori-Tanaka permite a obtenção da matriz de rigidez efetiva ($\bar{C}$), e, conseqüentemente, o cálculo das propriedades elásticas efetivas do compósito. A equação da matriz de rigidez para este método é dada por

$$\bar{C} = [(1 - f)C_m + fC_{in}A][(1 - f)I + fA]^{-1} \quad (1)$$

De modo que C_m e C_{in} representam as matrizes constitutivas da matriz e das inclusões, respectivamente, f a fração volumétrica de fibras, I a matriz identidade. Além disso, a matriz A pode ser calculada pela Equação 2, a seguir.

$$A = [I + S(C_m^{-1}C_{in} - I)]^{-1} \quad (2)$$

na qual S é o tensor de Eshelby para inclusão cilíndrica com uma das dimensões infinitas, tratando-se de uma fibra longa unidirecional.

Esquema Diferencial: Fundamentos e Aplicações

A elaboração do Esquema Diferencial é motivada pela observação de que os métodos clássicos de Eshelby e Mori-Tanaka fornecem estimativas com ótima precisão para pequenas frações de inclusões. Bohm (2020) revela que o Esquema Diferencial consiste na adição de inclusões, em pequenas concentrações, de forma cíclica e seguida de homogeneização, descrevendo as propriedades elásticas do compósito por meio de equações diferenciais. Qu e Cherkaoui (2006) apresentam as equações do Esquema Diferencial, tanto a partir do Método de Eshelby quanto do Método de Mori-Tanaka. A equação do Esquema Diferencial, utilizando Eshelby, para o cálculo da matriz de rigidez efetiva do compósito é dada por (Eq. 3):

$$\frac{d\bar{C}}{df} = \frac{1}{1-f} (C_{in} - \bar{C})[I + S(\bar{C}^{-1}C_{in} - I)]^{-1} \quad (3)$$

2.2 Inteligência Artificial e Modelos de Linguagem Grandes (LLMs) na Educação

A Inteligência Artificial (IA) tem se consolidado como uma ferramenta poderosa e transformadora em diversos setores, com um impacto crescente e notável na educação. Os Grandes Modelos de Linguagem (LLMs), em particular, têm revolucionado a forma como o conteúdo educacional é criado, disseminado e consumido, oferecendo novas oportunidades para o aprendizado personalizado e adaptativo (Hu et al., 2025).

A ascensão da IA na educação está redefinindo os papéis tradicionais, permitindo que a tecnologia complemente o trabalho dos educadores ao assumir tarefas rotineiras e repetitivas. Segundo Kamalov et al. (2025), essa automação abrange desde a tutoria personalizada e a avaliação de trabalhos até a geração de conteúdo. Apesar dos avanços, a implementação da IA ainda apresenta desafios, como a dependência de dados de treinamento estáticos e a adaptabilidade limitada dos LLMs convencionais, o que tem levado à exploração de fluxos de trabalho agentivos para melhorar o raciocínio da IA na educação.

Além de otimizar os processos pedagógicos, a IA também desempenha um papel fundamental na promoção da inclusão educacional, fornecendo suporte personalizado e recursos de aprendizado adaptativos em larga escala (Fitas, 2025). A IA Generativa, por exemplo, oferece ferramentas e metodologias que redefinem a criação e o consumo de conhecimento, otimizando ambientes de aprendizado dialogados (Hu et al., 2025). Contudo, para que o potencial da IA seja plenamente realizado, são necessárias estruturas de implementação éticas e inclusivas, que abordem questões como a privacidade de dados e a equidade de acesso (Fitas, 2025).

A adoção da IA na educação superior tem revelado tanto oportunidades quanto desafios, influenciando as práticas e percepções dos instrutores. Estudos mostram que a confiança e a desconfiança na IA Generativa são fatores distintos, com variações significativas na familiaridade dos instrutores com essa tecnologia (Lyu, et al., 2025). Isso ressalta a importância de orientações sobre o uso e o mau uso da IA na educação, bem como a necessidade de desenvolvimento de uma alfabetização responsável em IA, que ensine não apenas os fundamentos técnicos, mas também suas implicações éticas, sociais e de privacidade (Oye, Frank e Owen, 2024).

A capacidade da IA de analisar estilos de aprendizado individuais e preferências pode levar à criação de caminhos de aprendizado altamente personalizados, gerando conteúdo educacional adaptado, atividades e avaliações em tempo real. Essa personalização, combinada com a automação de avaliação e feedback, permite que os educadores se concentrem em interações mais qualificadas e um ensino de nível superior. De acordo com Chakraborty (2024), a integração da IA na sociedade educacional moderna é vista como um passo para a Educação 5.0, promovendo a colaboração entre humanos e máquinas e preparando os alunos com as habilidades e adaptabilidade necessárias para o futuro.

3 METODOLOGIA

Visando a construção de uma ferramenta computacional interativa para a determinação de propriedades efetivas em micromecânica de materiais, este trabalho tem como metodologia o relato de experiência, com enfoque no processo colaborativo com a Inteligência Artificial. Os procedimentos metodológicos foram divididos em etapas que englobaram a definição do problema, a colaboração com a IA para desenvolvimento de códigos em ambiente de programação (MATLAB), a transição e construção da *webapp* em ambiente web (HTML/JavaScript), a validação da ferramenta desenvolvida e, por fim, a análise dos resultados.

3.1 Definição dos Problemas e Requisitos

A situação problema principal para o desenvolvimento da *webapp* girou em torno da determinação de propriedades elásticas efetivas de materiais compósitos heterogêneos. O cenário estabelecido como requisitos para a funcionalidade da ferramenta, foi inspirado em um problema proposto no âmbito da disciplina de Micromecânica de Materiais Heterogêneos do Programa de Pós-Graduação em Engenharia Civil (PPGEC) da Universidade Federal de Alagoas (UFAL).

O problema consistia em avaliar o Módulo de Young (ou Elasticidade) Efetivo (E_{ef}) e o Coeficiente de Poisson Efetivo (ν_{ef}) de uma argamassa com matriz de pasta de cimento e inclusões esféricas de areia. Os valores das propriedades elásticas dos materiais constituintes da argamassa foram dados no enunciado do problema e estão expressos na Tabela 1.

Tabela 1 – Propriedades elásticas dos constituintes.

Material	Módulo de Young (GPa)	Coeficiente de Poisson
Pasta de Cimento	25	0,15
Areia	70	0,20

Fonte: Elaborado pelos autores, 2025.

Os modelos micromecânicos a serem implementados eram o de Mori-Tanaka e o Esquema Diferencial, para frações volumétricas de areia que variavam de 20% a 70%. As inclusões (grãos de areia) foram consideradas cilíndricas para o cálculo do Tensor de Eshelby. Além disso, um requisito crucial para essa etapa era a explicitação completa dos tensores e matrizes constituintes (rigidez e flexibilidade), bem como do tensor de Eshelby, diretamente no código, sem chamadas a funções auxiliares genéricas. Além disso, o cálculo final do Módulo de Young Efetivo (E_{ef}) e do Coeficiente de Poisson Efetivo (ν_{ef}) é realizado pela inversão da matriz de rigidez efetiva, encontra-se a matriz de flexibilidade efetiva, D_{ef} , em seguida utilizando as relações $E_{ef} = 1/D_{11}$ e $\nu_{ef} = -D_{12}/D_{11}$, com os resultados apresentados com quatro casas decimais para maior precisão. Vale lembrar que para representação dos tensores foi adotado a notação de Voigt.

3.2 Colaboração com a Inteligência Artificial (ChatGPT) para Desenvolvimento dos Códigos MATLAB

O desenvolvimento dos códigos em MATLAB, que serviriam de base para a webapp, foi realizado em um processo de intensa colaboração com a Inteligência Artificial, por meio da interface de conversação do *ChatGPT*. Esta abordagem permitiu superar a limitação de um conhecimento aprofundado em programação, concentrando-se na lógica e nos princípios micromecânicos.

Inicialmente, foram solicitadas ao *ChatGPT* funções em MATLAB para a implementação dos modelos de Mori-Tanaka e Esquema Diferencial para inclusões esféricas. Durante o processo, foi especificado que as equações dos tensores de Eshelby e das matrizes de rigidez e flexibilidade fossem explicitamente inseridas no corpo das funções, garantindo transparência e controle sobre cada etapa do cálculo. A IA gerou as funções correspondentes, que foram então utilizadas em scripts de avaliação para analisar o comportamento das propriedades efetivas em diferentes frações volumétricas e para realizar comparações entre os métodos. A partir desses scripts, gráficos comparativos do módulo de Young e do coeficiente de Poisson foram gerados, permitindo uma visualização clara das tendências e diferenças entre os modelos.

3.3 Transição para o Desenvolvimento da WebApp em HTML/JavaScript

Após o desenvolvimento e validação dos códigos em MATLAB, a etapa seguinte consistiu na transição para a criação de uma *webapp* acessível via navegador web. A escolha de HTML e JavaScript permitiu a construção de uma ferramenta acessível via navegador web, sem a necessidade de softwares específicos ou licenças. A IA foi novamente utilizada como principal ferramenta de desenvolvimento, sendo solicitada a construir um sistema simples em HTML, onde o usuário pudesse fornecer os dados de entrada e obter os resultados das propriedades efetivas calculadas pelos dois métodos (Mori-Tanaka e Esquema Diferencial).

A *webapp*, intitulada "*Calculadora de Propriedades Efetivas*", foi desenvolvida em HTML para a estrutura da interface e JavaScript para a lógica de programação. A biblioteca *Math.js* foi integrada ao ambiente JavaScript para realizar as operações matriciais complexas necessárias aos cálculos micromecânicos. Os algoritmos de Mori-Tanaka e Esquema Diferencial foram adaptados e implementados diretamente em JavaScript, permitindo que a aplicação realizasse os cálculos internamente e exibisse os resultados de E_{ef} (em GPa) e ν_{ef} . A interface da ferramenta permitiu aos usuários inserir os Coeficientes de Poisson e Módulos de Young da matriz e da inclusão, bem como a fração volumétrica.

3.4 Validação da Ferramenta Desenvolvida

A validação da "*Calculadora de Propriedades Efetivas*" foi uma etapa crucial para garantir a acurácia e a confiabilidade da ferramenta. Este processo foi realizado por meio de uma análise comparativa extensiva dos resultados gerados pela *webapp* com valores reportados na literatura para modelos de mistura, bem como com os resultados obtidos pelos códigos MATLAB desenvolvidos paralelamente.

Essa validação abrangente incluiu os seguintes cenários de comparação: mistura asfáltica (Marques, 2025), concreto (Pianezzet al., 2016) e concreto leve (Miled et al., 2007). Os dados de entrada para análise comparativa encontram-se detalhados na Tabela 2.

Tabela 2 – Cenários para comparação.

Material Compósito	E_m (GPa)	ν_m	E_{in} (GPa)	ν_{in}	f (%)
Mistura asfáltica	1,32	0,3	40,5	0,2	8,37
Concreto	30,0	0,3	51,0	0,13	15,0
Concreto Leve	41,0	0,2	0,01	0,2	30

Fonte: Elaborado pelos autores, 2025.

Em todos os casos de comparação, foram consideradas inclusões esféricas. A concordância entre os resultados da *webapp* e os dados de referência confirmou a acurácia e a confiabilidade da ferramenta desenvolvida com o auxílio da Inteligência Artificial.

3.5 Análise e Avaliação dos Resultados

Os resultados das propriedades efetivas da argamassa, obtidos, pela Calculadora de Propriedades Efetivas, para as diferentes frações volumétricas de areia (20%, 30%, 40%, 50%, 60% e 70%) utilizando os modelos de Mori-Tanaka e Esquema Diferencial, foram analisados e avaliados. Os dados foram compilados e apresentados em tabelas e gráficos comparativos para facilitar a visualização das tendências e a comparação entre os dois métodos micromecânicos.


Por fim, o trabalho buscou levantar uma discussão sobre a contribuição da IA no processo de aprendizagem e no desenvolvimento de instrumentos computacionais, explorando o potencial facilitador técnico e educacional da IA, uma vez que atuou acelerando a compreensão de conceitos complexos e democratizando o acesso à construção de ferramentas.

4 RESULTADOS E DISCUSSÃO

4.1 Apresentação da WebApp "Calculadora de Propriedades Efetivas"

A "Calculadora de Propriedades Efetivas" é uma aplicação web interativa desenvolvida em HTML/JavaScript, com o auxílio da biblioteca *Math.js* para operações matriciais. A ferramenta foi desenvolvida com êxito com a colaboração de inteligência artificial para construção dos códigos. Sua função é auxiliar na determinação das propriedades elásticas efetivas de compósitos com inclusões esféricas, utilizando os modelos micromecânicos de Mori-Tanaka e Esquema Diferencial. A Figura 1 apresenta a interface da Calculadora de Propriedades Efetivas.

Figura 1 – Interface da Calculadora de Propriedades Efetivas.



A interface da calculadora é um formulário web com o título "Calculadora de Propriedades Efetivas". Abaixo do título, há uma instrução: "Informe os parâmetros (Em GPa para módulos, v adimensional, f fracionário):". O formulário contém cinco campos de entrada, cada um com uma label e um valor pré-definido: v_m (Poisson matriz) com o valor 0.15, E_m (Young matriz, GPa) com o valor 25, v_{in} (Poisson inclusão) com o valor 0.20, E_{in} (Young inclusão, GPa) com o valor 70, e f (fração volumétrica) com o valor 0.3. Abaixo dos campos, há um botão "Calcular". Na base do formulário, há uma área vazia para a saída dos resultados.

Fonte: Elaborado pelos autores, 2025.

É possível observar a interface amigável da ferramenta permite ao usuário inserir os coeficientes de Poisson e Módulos de Young da matriz e da inclusão (v_m , E_m , v_{in} , E_{in}), bem como a fração volumétrica da inclusão (f). Ao clicar no botão "calcular", o usuário recebe, em

segundos, os resultados das propriedades elásticas efetivas para o material compósito com as características dos dados de entrada. Nos testes realizados, a ferramenta não apresentou nenhum tipo problema. O código desenvolvido encontra-se disponível no link: <https://github.com/eliedsonr/COBENGE25-00/blob/main/CPROEFE-00>.

4.2 Validação dos Resultados da WebApp e Comparação com a Literatura

Para validar a solução e garantir a confiabilidade da "Calculadora de Propriedades Efetivas", os resultados gerados pela webapp foram comparados com valores reportados na literatura para diferentes modelos de mistura e, adicionalmente, replicados em MATLAB para confirmação. Esta validação comparativa considerou inclusões esféricas em todos os casos.

A Tabela 3 apresenta o comparativo para validação da calculadora com dados da literatura:

Tabela 3 – Comparativo para validação da Calculadora de Propriedades Efetivas

Comparação 1 – (Marques, 2025) – Mistura Asfáltica

Método	Literatura	MATLAB	Calculadora
Mori-Tanaka	$E = 1.5592 \text{ MPa}$	$E = 1.5591 \text{ MPa}$	$E = 1.5591 \text{ MPa}$
Esquema Diferencial	$E = 1.5692 \text{ MPa}$	$E = 1.5692 \text{ MPa}$	$E = 1.5692 \text{ MPa}$

Comparação 2 – (Pianezzer et al., 2016) – Concreto

Método	Literatura	MATLAB	Calculadora
Mori-Tanaka	$E = 32.3 \text{ GPa}$	$E = 32.5903 \text{ GPa}$	$E = 32.5903 \text{ GPa}$
Mori-Tanaka	$\nu = 0.279$	$\nu = 0.2799$	$\nu = 0.2799$

Comparação 3 – (Miled et al., 2007) – Concreto Leve

Método	Literatura (Exp.)	MATLAB	Calculadora
Mori-Tanaka	$E = 20-22 \text{ GPa}$	$E = 22.2288 \text{ GPa}$	$E = 22.2288 \text{ GPa}$
Esquema Diferencial	$E = 20-22 \text{ GPa}$	$E = 20.3011 \text{ GPa}$	$E = 20.3011 \text{ GPa}$

Fonte: Elaborado pelos autores, 2025.

A primeira comparação, utilizando dados de uma mistura asfáltica demonstrou que o modelo de Mori-Tanaka na *webapp* e no MATLAB obteve $E_{ef} = 1,5591 \text{ MPa}$, em concordância com o valor da literatura de 1.5592 MPa . Para o Esquema Diferencial, o valor de $E_{ef} = 1,5692 \text{ MPa}$ também foi consistente em todas as plataformas.

Na segunda comparação, com dados de concreto a calculadora e o MATLAB apresentaram $E_{ef} = 32,5903 \text{ GPa}$ e $\nu_{ef} = 0,2799$ para o modelo de Mori-Tanaka, próximos aos valores da literatura de $E = 32,3 \text{ GPa}$ e $\nu = 0.279$.

Finalmente, na comparação com dados de concreto leve, a Calculadora e o MATLAB obtiveram $E_{ef} = 22,2288 \text{ GPa}$ para Mori-Tanaka e $E_{ef} = 20,3011 \text{ GPa}$ para o Esquema Diferencial, valores que se alinham com a faixa experimental da literatura de $E_{ef} = 20-22 \text{ GPa}$. A consistência dos resultados entre a Calculadora, o MATLAB e a literatura validam a acurácia da ferramenta desenvolvida.

4.3 Análise dos Resultados Obtidos pela Calculadora

Com a validação da ferramenta, foram obtidos os resultados das propriedades efetivas da argamassa para as diferentes frações volumétricas de areia (20%, 30%, 40%, 50%, 60% e 70%) utilizando a Calculadora de Propriedades Efetivas. Os resultados completos são expressos na Figura 2.


Figura 2 – Resultados obtidos para as propriedades efetivas através da calculadora

20%	30%	40%	50%	60%	70%
Resultados	Resultados	Resultados	Resultados	Resultados	Resultados
Mori-Tanaka: $E_{ef} = 30.2719 \text{ GPa}$ $v_{ef} = 0.1608$	Mori-Tanaka: $E_{ef} = 33.3377 \text{ GPa}$ $v_{ef} = 0.1658$	Mori-Tanaka: $E_{ef} = 36.7571 \text{ GPa}$ $v_{ef} = 0.1705$	Mori-Tanaka: $E_{ef} = 40.5956 \text{ GPa}$ $v_{ef} = 0.1752$	Mori-Tanaka: $E_{ef} = 44.9360 \text{ GPa}$ $v_{ef} = 0.1799$	Mori-Tanaka: $E_{ef} = 49.8842 \text{ GPa}$ $v_{ef} = 0.1846$
Esquema Diferencial: $E_{ef} = 30.3832 \text{ GPa}$ $v_{ef} = 0.1612$	Esquema Diferencial: $E_{ef} = 33.5822 \text{ GPa}$ $v_{ef} = 0.1665$	Esquema Diferencial: $E_{ef} = 37.1775 \text{ GPa}$ $v_{ef} = 0.1716$	Esquema Diferencial: $E_{ef} = 41.2170 \text{ GPa}$ $v_{ef} = 0.1766$	Esquema Diferencial: $E_{ef} = 45.7527 \text{ GPa}$ $v_{ef} = 0.1815$	Esquema Diferencial: $E_{ef} = 50.8398 \text{ GPa}$ $v_{ef} = 0.1862$

Fonte: Elaborado pelos autores, 2025.

A análise gráfica do comportamento do Módulo de Young Efetivo e do Coeficiente de Poisson Efetivo em função da fração volumétrica de areia, comparando os modelos de Mori-Tanaka e Esquema Diferencial, é apresentada na Figura 3 que foi construída no MATLAB.

Figura 3 – Resultados obtidos para as propriedades efetivas através da calculadora



Fonte: Elaborado pelos autores, 2025.

Observa-se na Figura 3 que ambos os modelos apresentam uma tendência de aumento no Módulo de Young Efetivo com o crescimento da fração volumétrica de areia, igualmente verificada nos dados da Calculadora. Essa tendência é esperada, visto que a areia possui um Módulo de Young superior ao da pasta de cimento, contribuindo para a rigidez global do compósito.

Os resultados dos dois modelos se mantêm próximos, indicando coerência nas previsões. Para o coeficiente de Poisson efetivo, a tendência também é de aumento com o incremento da fração de areia, embora a variação seja menos acentuada que a do módulo de

Young. A proximidade das curvas entre os modelos Mori-Tanaka e Esquema Diferencial reforça a robustez das estimativas para este tipo de compósito.

4.4 Discussão sobre a Contribuição da IA no Processo de Aprendizagem

A experiência de desenvolver a Calculadora de Propriedades Efetivas com o auxílio da Inteligência Artificial (ChatGPT) revelou a capacidade da IA de atuar como uma ferramenta facilitadora no processo de programação e aprendizado, superando barreiras técnicas e acelerando a compreensão de conceitos complexos. A interação dialógica com a IA permitiu a construção de códigos MATLAB complexos para micromecânica, mesmo com um conhecimento básico em programação, o que tradicionalmente exigiria um domínio muito maior de sintaxe e lógica algorítmica.

A IA demonstrou ser um "parceiro" eficiente na explicitação de tensores e matrizes, na geração de scripts de avaliação e na adaptação de códigos para diferentes ambientes (MATLAB para HTML/JavaScript). Essa capacidade de traduzir a lógica matemática para diferentes linguagens de programação, sem a necessidade de intervenção humana detalhada em cada linha de código, agilizou significativamente o processo de desenvolvimento da webapp. Além disso, a IA atuou como um "tutor inteligente", fornecendo feedback instantâneo sobre a funcionalidade do código e sugerindo ajustes que aprimoraram a acurácia dos modelos.

Do ponto de vista do aprendizado, a utilização da IA transformou a experiência de desenvolvimento em um ambiente de "playground socrático", onde o conhecimento foi construído de forma iterativa e exploratória (Hu et al., 2025). A IA permitiu que o foco se deslocasse da memorização de sintaxes para a compreensão dos princípios fundamentais da micromecânica, dos algoritmos de homogeneização e das interações entre as variáveis. Ao externalizar a complexidade da codificação, a IA liberou recursos cognitivos para a análise crítica dos resultados, a comparação com a literatura e a interpretação do comportamento dos materiais. Isso exemplifica como a IA pode democratizar o acesso ao desenvolvimento de ferramentas computacionais, capacitando indivíduos com diferentes níveis de proficiência em programação a criar soluções complexas e, conseqüentemente, a aprofundar seu aprendizado em engenharia. A IA, portanto, não apenas otimizou o processo de desenvolvimento, mas também serviu como uma poderosa ferramenta didática, tornando o aprendizado mais interativo e eficaz.

5 CONSIDERAÇÕES FINAIS

Este trabalho relatou a experiência de desenvolvimento e validação de uma *webapp* interativa, a "Calculadora de Propriedades Efetivas", para a homogeneização de materiais com inclusões esféricas. O processo demonstrou a viabilidade e o potencial da Inteligência Artificial como uma ferramenta facilitadora no ensino de engenharia, especialmente em disciplinas que envolvem conceitos complexos como a micromecânica de materiais.

A colaboração com a IA permitiu a superação de barreiras técnicas na programação e na adaptação de algoritmos complexos, resultando em uma ferramenta funcional e precisa. A validação da *webapp*, por meio da comparação de seus resultados com dados da literatura e com códigos MATLAB, confirmou a acurácia das previsões dos modelos de Mori-Tanaka e Esquema Diferencial para as propriedades efetivas de compósitos.

A experiência evidenciou que a IA pode atuar como um catalisador do aprendizado, não apenas automatizando tarefas de codificação, mas também permitindo que o foco se desloque para a compreensão conceitual e a análise crítica dos resultados. Isso sugere que a Inteligência Artificial tem um papel promissor na democratização do acesso a ferramentas computacionais e na otimização do processo de ensino-aprendizagem em engenharia, ao

transformar a complexidade técnica em um ambiente mais acessível e interativo para estudantes e educadores.

Como limitações deste estudo, destaca-se que a *webapp* foi desenvolvida exclusivamente para inclusões esféricas. Para trabalhos futuros, sugere-se a expansão da ferramenta para contemplar diferentes geometrias de inclusão, como fibras e plaquetas, e a inclusão de outros modelos de homogeneização para aumentar sua versatilidade. Além disso, a incorporação de recursos de visualização 3D das microestruturas poderia enriquecer ainda mais a experiência de aprendizado, tornando a ferramenta ainda mais didática.

AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Civil (PPGEC) da UFAL e ao Instituto Federal de Alagoas (IFAL) pelo suporte institucional, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Alagoas (FAPEAL) pelo apoio financeiro e concessão de bolsa.

REFERÊNCIAS

BOHM, H. J. **A short introduction to basic aspects of continuum micromechanics**. Vienna University of Technology, Institute of Lightweight Design and Structural Biomechanics (ILSB), 2020.

CARVALHO, E. R. de; CARVALHO, J. L. B. de; COSTA, L. E. N.; SILVA, I. Q. L. C. Microrrevisões de matemática via aplicativo móvel: estudo com alunos do ensino fundamental sobre suas percepções e resultados educacionais. **Revista Caderno Pedagógico**, Curitiba, v. 21, n. 13, p. 01-22, 2024.

CARVALHO, E. R. de; CAVALCANTE, M. A. A.; MARQUES, S. P. C. Análise comparativa entre modelos da micromecânica e valores experimentais das propriedades de materiais compósitos reforçados por fibras longas unidirecionais. In: CILAMCE, XLI IBERO-LATIN AMERICAN CONGRESS ON COMPUTATIONAL METHODS IN ENGINEERING, 2020, Foz do Iguaçu. **Anais...** Foz do Iguaçu: ABMEC, 2020. p. 1-7.

CHAKRABORTY, S. Generative AI in Modern Education Society. **arXiv**, 2024. Disponível em: <https://arxiv.org/html/2412.08666v1>. Acesso em: 21 maio 2025.

FITAS, R. Inclusive Education with AI: Supporting Special Needs and Tackling Language Barriers. **arXiv**, 2025. Disponível em: <https://arxiv.org/pdf/2504.14120>. Acesso em: 30 maio 2025.

HU, X.; XU, S.; TONG, R.; GRASSER, A. Generative AI in Education: From Foundational Insights to the Socratic Playground for Learning. **arXiv**, 2025. Disponível em: <https://arxiv.org/html/2501.06682v1>. Acesso em: 22 maio 2025.

JONES, R. M. **Mechanics of composite materials**. 2. ed. Taylor & Francis, 1999.

KAMALOV, et al. Evolution of AI in Education: Agentic Workflows. **arXiv**, 2025a. Disponível em: <https://arxiv.org/pdf/2504.20082>. Acesso em: 25 maio 2025.

KAW, A. K. **Mechanics of Composite Materials**. 2. ed. Taylor & Francis, 2006.

KIM, J.; KELLY, S.; PRAHL, A. Navigating AI in education: foundational suggestions for leveraging AI in teaching and learning. **Taylor & Francis Online**, 2025.

LYU, et al. Understanding the Practices, Perceptions, and (Dis)Trust of Generative AI among Instructors: A Mixed-methods Study in the U.S. Higher Education. **arXiv**, 2025. Disponível em: <https://arxiv.org/html/2502.05770v1>. Acesso em: 30 maio 2025.

MARQUES, S. P. C. **Notas de Aula: Micromecânica de Materiais Heterogêneos**. Universidade Federal de Alagoas - UFAL. Programa de Pós Graduação em Engenharia Civil - PPGE. Maceió-AL, 2025.

MILED, K.; SAB, K.; LE ROY, R. Particle size effect on EPS lightweight concrete compressive strength: Experimental investigation and modelling. **Mechanics of Materials**, v. 39, n. 3, p. 222-240, 2007.

OYE, E.; FRANK, E.; OWEN, J. Ethical Considerations of AI in Education: A Critical Review. **ResearchGate**, 2024. Disponível em: https://www.researchgate.net/publication/387275777_Ethical_Considerations_in_AI-Driven_Education. Acesso em: 20 maio 2025.

PIANEZZER, Guilherme Augusto et al. Aplicação dos Métodos de Homogeneização para Obtenção das Propriedades Efetivas do Concreto. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 5, n. 1, 2017.

QU, J.; CHERKAoui, M. **Fundamentals of micromechanics of solids**. John Wiley & Sons, Inc., 2006.

APPLICATIONS OF ARTIFICIAL INTELLIGENCE IN ENGINEERING EDUCATION: FROM THEORY TO PRACTICE WITH THE CREATION OF A WEBAPP FOR MATERIAL HOMOGENIZATION

Abstract. *The integration of Artificial Intelligence (AI) in engineering education has revolutionized the teaching-learning process, offering new opportunities and challenges. This study aims to report the experience of developing an interactive webapp for material homogenization, using AI support for the creation and adaptation of codes. The methodological procedures were divided into stages that included defining the problem, collaborating with AI to develop codes in a programming environment (MATLAB), transitioning and building the webapp in a web environment (HTML/JavaScript), validating the developed tool, and, finally, analyzing the results. The main results demonstrate the accuracy of the webapp in predicting effective properties and highlight AI's potential as a technical and didactic facilitator, optimizing the construction of computational tools and deepening the learning of engineering concepts.*

Keywords: Artificial Intelligence, Civil Engineering, Micromechanics, Webapp.

