

# Machine Learning Algorithms to Estimate Composite Mechanical Properties

Janaina Gomide<sup>1</sup>, Lucas Vignoli<sup>1</sup>, Yuri Macedo<sup>1</sup>

<sup>1</sup>Instituto Politécnico - Universidade Federal do Rio de Janeiro (UFRJ)

{janainagomide, lucas.lvig}@gmail.com, yuri.macedo@me.com

**Abstract.** *Structures made of composite materials have been implemented in several sectors such as transport, civil construction, maritime and aerospace. The focus of this study is unidirectional composites that have 5 independent properties. Obtaining these properties can be done experimentally, numerically and analytically. In this article we propose an alternative way to estimate these properties, using machine learning algorithms. The goal of this paper is to evaluate machine learning algorithms to generate the estimation of these 5 properties of composites. Experiments were carried out with two distinct data sets and the results obtained were satisfactory.*

**Resumo.** *Estruturas feitas de materiais compósitos têm sido implementadas em diversos setores como transporte, construção civil, marítimo e aeroespacial. O foco deste estudo são os compósitos unidirecionais que possuem 5 propriedades independentes. A obtenção dessas propriedades pode ser feita experimentalmente, numericamente e analiticamente. Neste artigo vamos propor uma forma alternativa de estimar essas propriedades, usando algoritmos de aprendizado de máquina. O objetivo deste artigo é avaliar algoritmos de aprendizado de máquina para gerar a estimativa dessas 5 propriedades de compósitos. Experimentos foram realizados com dois conjuntos de dados distintos e os resultados obtidos foram satisfatórios.*

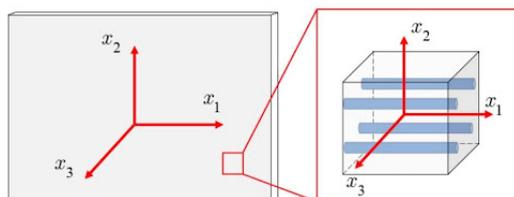
## 1. Introdução

O material a ser escolhido em um projeto estrutural de engenharia é de grande importância, visto os riscos de falha do material se as propriedades mecânicas do mesmo não atenderem aos requisitos do projeto.

Estruturas feitas de materiais compósitos têm sido implementadas em diversos setores, com destaque no transporte, construção civil, marítimo e aeroespacial, [Ventura 2009]. No entanto, para a utilização de compósito em um projeto estrutural, é preciso conhecer as propriedades mecânicas do mesmo para realizar o dimensionamento adequado.

Os materiais compósitos são o resultado da combinação de dois ou mais materiais, na forma de matriz e de reforços. A matriz pode ser metálica, polimérica ou cerâmica. Por outro lado, o material de reforço é classificado como partícula ou fibra. Os reforços podem ser de uma ampla gama de materiais, como vidro, carbono e bambu. Tal combinação permite a maior customização das propriedades mecânicas efetivas desejadas no compósito para atender à necessidade de um determinado projeto, tanto para obter melhores propriedades com um menor peso, quanto obter um menor custo [Shahinur and Hasan 2020].

O foco deste estudo são os compósitos de matriz polimérica reforçada com fibras unidirecionais. Estes laminados unidirecionais são anisotrópicos e possuem 5 propriedades elásticas independentes: o módulo de elasticidade longitudinal,  $E_1$ ; o módulo de elasticidade transversal,  $E_2$ ; o módulo de cisalhamento longitudinal,  $G_{12}$ ; o módulo de cisalhamento transversal,  $G_{23}$ ; e o coeficiente de Poisson longitudinal,  $\nu_{12}$ . A Figura 1 apresenta o sistema de coordenadas utilizado para definir as propriedades e ilustra um laminado unidirecional, tanto do ponto de vista macromecânico quanto micromecânico.



**Figura 1. Sistema de coordenadas utilizado para definir as propriedades do compósito.**

Para obtenção das propriedades das lâminas, pode-se utilizar três abordagens distintas: experimental, numérica e analítica. A caracterização experimental necessita de quatro testes diferentes para cada combinação de matriz, lâmina e fração volumétrica, sendo preciso repetir esses testes diversas vezes por questões estatísticas. Desta forma, a caracterização experimental de laminados unidirecionais necessita de um grande investimento de tempo e um alto custo, impossibilitando a otimização do projeto e tornando-a menos interessante em uma primeira avaliação [Merayo et al. 2020].

Uma forma alternativa para obter as propriedades macromecânicas do compósito é a utilização de modelos micromecânicos, onde apenas as propriedades dos constituintes (i.e. matriz e fibra) são necessárias. Desta forma, pode-se avaliar a influência de diferentes combinações entre fibras e matrizes, assim como suas frações volumétricas. Diversos modelos analíticos e numéricos têm sido desenvolvidos com este objetivo, como revisado por [Vignoli et al. 2019].

Alguns autores têm estudado a implementação de algoritmos de aprendizado de máquina na estimação das propriedades de diferentes materiais a partir de diferentes dados de entrada. [Pathan et al. 2019] utilizaram a micrografia (imagem da microestrutura do material) de compósitos. [Merayo et al. 2020] avaliaram a composição química de ligas metálicas. [Wang et al. 2021] estudaram estruturas tubulares de compósitos reforçados com fibras de carbono trançadas. [Guo et al. 2021] utilizaram 10 propriedades de mistura do material, juntamente de 4 propriedades físicas de compósitos cimentícios reforçados com fibra de alto desempenho. [Rajput et al. 2022] utilizaram 8 parâmetros dos materiais e 3 parâmetros do processo de fabricação de compósitos de matriz de metal híbrido à base de alumínio.

No entanto, nenhum destes trabalhos possui a abrangência da metodologia proposta. O presente estudo visa avaliar a aplicação do aprendizado de máquinas para laminados unidirecionais com matrizes poliméricas, considerando tanto as fibras de vidro quanto as fibras de carbono. O objetivo deste trabalho é apresentar uma modelagem micromecânica, onde são utilizadas as propriedades das fibras e da matriz, para obter as propriedades efetivas macromecânicas.

Este artigo possui como objetivo implementar e avaliar algoritmos de aprendizado de máquina na estimativa das propriedades mecânicas de lâminas de materiais compósitos reforçadas com fibras unidirecionais. Dessa forma, este trabalho tem como motivação implementar um método alternativo aos experimentais, visando a redução dos gastos, e dos métodos analíticos, buscando desempenho semelhante ao obter as propriedades. Os conjuntos de dados sobre compósitos unidirecionais são apresentados na Seção 2 juntamente com a explicação de quais são os atributos, quais as saídas e quantidade de exemplos em cada conjunto de dados. A metodologia é discutida na Seção 3. Os resultados obtidos são apresentados na Seção 4. Por último, a Seção 5 resume as principais conclusões deste estudo.

## 2. Conjunto de Dados de Compósitos Unidirecionais

O objetivo desta seção é descrever a representação micromecânica dos materiais compósitos e apresentar os dois conjuntos de dados que serão utilizados nos modelos de aprendizado de máquina.

Deseja-se criar modelos de aprendizado de máquina para obter os valores das propriedades efetivas das lâminas ( $E_1$ ,  $E_2$ ,  $G_{12}$ ,  $G_{23}$  e  $\nu_{12}$ ), conforme introduzido na seção anterior. Para isso, utiliza-se como entrada as seguintes propriedades dos constituintes: o módulo de elasticidade da matriz,  $E_m$ ; o coeficiente de Poisson da matriz,  $\nu_m$ ; o módulo de elasticidade longitudinal da fibra,  $E_{1f}$ ; o módulo de elasticidade transversal da fibra,  $E_{2f}$ ; o módulo de cisalhamento longitudinal da fibra,  $G_{12f}$ ; o módulo de cisalhamento transversal da fibra,  $G_{23f}$ ; o coeficiente de Poisson longitudinal da fibra,  $\nu_{12f}$ ; e a fração volumétrica da fibra,  $V_f$ .

Dessa forma, os dados de entrada para o modelo de aprendizado de máquina possuem 8 atributos que são as cinco propriedades da fibra, as duas propriedades da matriz e a fração volumétrica de fibra. O modelo de aprendizado de máquina deve prever as cinco propriedades elásticas da lâmina do compósito.

Dois conjuntos de dados são utilizados na criação dos modelos de aprendizado de máquina: um conjunto de dados que reúne informações dos compósitos obtidos de forma experimental e um conjunto de dados gerado a partir de um modelo analítico. Esses conjuntos são descritos em detalhes a seguir.

### 2.1. Conjunto de dados obtidos por meio de experimentos em laboratório

Os dados experimentais das propriedades mecânicas da lâmina do compósito, juntamente das propriedades mecânicas da matriz e da fibra, e a fração volumétrica da fibra foram coletados de informações presentes em quatorze artigos. Esses artigos apresentaram experimentos em um total de 24 lâminas e resultou em um total de 90 exemplos para comporem o conjunto de dados experimentais. Na Tabela 1 são apresentados os artigos e a quantidade de exemplos obtidos para formar o conjunto de dados.

A Tabela 2 apresenta os atributos de alguns exemplos desse conjunto de dados. Os atributos, que são utilizados como entrada no algoritmo de aprendizado de máquina são as propriedades da matriz e fibra, juntamente da fração volumétrica. Na Tabela 3 são apresentadas as propriedades da lâmina que são o valores que deseja-se estimar por meio dos modelos de aprendizado de máquina.

**Tabela 1. Referências dos artigos que contém dados experimentais das propriedades dos compósitos.**

Artigos	Fibra	Lâminas	Exemplos
[Kriz and Stinchcomb 1979], [Huang 2001]	Carbono	1	36
[Tsai and Hahn 1980]	Vidro	2	26
[Soden et al. 1998]	Carbono e Vidro	4	4
[Bledzki et al. 1999]	Vidro	1	4
[Yim and Gillespie Jr 2000]	Carbono	1	1
[Huang and Talreja 2005]	Carbono	1	1
[Camanho et al. 2007]	Carbono	1	1
[Lee and Soutis 2007]	Carbono	1	1
[Benzarti et al. 2001]	Vidro	1	5
[Kaddour and Hinton 2012]	Carbono e Vidro	5	5
[Kaddour et al. 2013]	Carbono e Vidro	4	4
[Schaefer et al. 2014]	Carbono	1	1
[Li et al. 2014]	Carbono	1	1
<b>Total:</b>		24	90

**Tabela 2. Entrada (atributos) para o modelo de aprendizado de máquina de alguns exemplos do conjunto de dados gerados por experimentos em laboratório.**

Lâmina	$V_f$	$E_{1f}$ (GPa)	$E_{2f}$ (GPa)	$G_{12f}$ (GPa)	$G_{23f}$ (GPa)	$\nu_{12f}$	$E_m$ (GPa)	$\nu_m$
15	0,6	276,0	15,0	27,0	7,0	0,2	4,08	0,38
16	0,6	231,0	15,0	15,0	7,0	0,2	0,95	0,35
17	0,6	231,0	15,0	15,0	7,0	0,2	3,20	0,35
18	0,6	87,0	87,0	36,0	36,0	0,2	3,20	0,35
19	0,6	74,0	74,0	30,8	30,8	0,2	3,35	0,35
20	0,6	276,0	19,0	27,0	7,0	0,2	4,08	0,38

## 2.2. Conjunto de dados gerados pelo modelo analítico

Uma outra forma de obtenção de dados das propriedades macromecânicas do compósito é a utilização de modelos micromecânicos, onde utiliza-se as propriedades dos constituintes (i.e. matriz e fibra) para gerá-las. De acordo com o trabalho apresentado em [Vignoli et al. 2019], o modelo de homogeneização assintótica, descrito no artigo [Bravo-Castillero et al. 2012], é o que possui as melhores estimativas, além de ter uma sólida base matemática e mecânica. Esse modelo será utilizado para gerar o segundo conjunto de dados que será utilizado nos modelos de aprendizado de máquina.

Desse modo, foi gerado um conjunto de dados contendo exemplos de dados de compósitos para fibras de fibra e fibras de carbono. Foram gerados um total de 124.585 exemplos, sendo 59.049 de fibra de vidro e 65.536 exemplos de fibra de carbono. Os valores utilizados para os parâmetros do modelo de homogeneização assintótica são apresentados na Tabela 4. Destaca-se que as fibras de vidro são isotrópicas e possuem duas propriedades elásticas independentes:  $E_{1f}$  e  $\nu_{12f}$ , sendo  $E_{2f}=E_{1f}$  e  $G_{12f}=G_{23f}=E_{1f}/2 \times (1+\nu_{12f})$ .

**Tabela 3. Propriedades da lâmina de alguns exemplos do conjunto de dados gerados por experimentos em laboratório - Saída esperada do modelo de aprendizado de máquina.**

Lâmina	$E_1$ (GPa)	$E_2$ (GPa)	$G_{12}$ (GPa)	$G_{23}$ (GPa)	$\nu_{12}$
15	165,0	8,4	5,6	2,8	0,34
16	129,0	5,6	1,3	1,9	0,318
17	140,0	10,0	6,0	3,3	0,30
18	52,0	19,0	6,7	6,7	0,30
19	45,6	16,2	5,8	5,7	0,278
20	165,0	9,0	5,6	2,8	0,34

**Tabela 4. Valores dos parâmetros do método analítico de homogeneização assintótica para geração de exemplos do conjunto de dados.**

Propriedades	Fibra de Vidro			Fibra de Carbono		
	Min	Max	Divisões	Min	Max	Divisões
$V_f$	0,3	0,75	8	0,3	0,75	3
$E_m$ (GPa)	1	6	8	1	6	3
$\nu_m$	0,3	0,4	8	0,3	0,4	3
$E_{1f}$ (GPa)	70	90	8	220	300	3
$E_{2f}$ (GPa)				10	40	3
$G_{12f}$ (GPa)				10	30	3
$G_{23f}$ (GPa)				5	15	3
$\nu_{12f}$	0,2	0,25	8	0,2	0,35	3

### 3. Metodologia

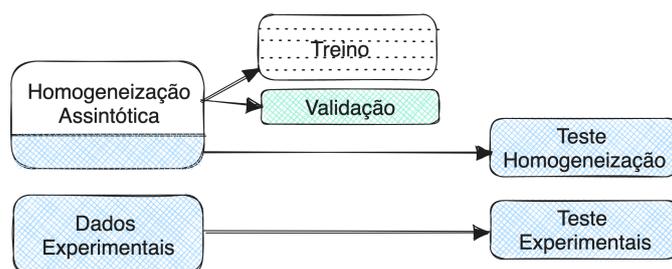
Esse trabalho foi desenvolvido por meio dos processos de obtenção de dados, pré-processamento do conjunto de dados, treinamento dos algoritmos de aprendizado de máquina e a verificação dos resultados por meio de métricas. O código para o aprendizado de máquina desse trabalho se encontra disponível em: <https://github.com/mlandengineering/compositePropertiesENIAC2023/>.

#### 3.1. Treinamento dos modelos

Para a realização dos experimentos foi utilizada a biblioteca ScikitLearn do Python e os experimentos foram executados no ambiente do Google Colaboratory.

A divisão dos conjuntos de dados em conjuntos de treino, validação e teste está representada na Figura 2. O conjunto de dados gerado pelo modelo analítico de homogeneização assintótica foi dividido em 80% para treino do modelo e 20% para teste do modelo, sendo distribuídos de forma aleatória. o conjunto de dados obtidos por experimentos em laboratório são utilizados apenas como teste para avaliar o modelo visto que são poucos exemplos disponíveis.

Os algoritmos de aprendizado de máquina utilizados para prever as propriedades foram regressão linear e árvores de decisão. Optou-se por implementar duas diferentes abordagens para geração da estimativa dos valores visto que a regressão linear é o algoritmo mais simples, sem hiperparâmetros e é útil para problemas de regressão simples,



**Figura 2. Divisão dos conjuntos de dados em conjuntos de treino, validação e teste.**

enquanto as árvores de decisão podem lidar com problemas de regressão mais complexos. O algoritmo de árvores de decisão possui como grande vantagem a sua capacidade de interpretabilidade, sendo possível a visualização gráfica que permite uma compreensão visual do modelo e das decisões tomadas em cada ramo e fornecem uma medida da importância relativa das variáveis na tomada de decisões. Ao utilizar esses dois algoritmos, é possível comparar também qual seria necessário para abordar o problema e mitigar o risco de superajuste.

Para o algoritmo de árvores de decisão foi explorado variações do hiperparâmetro de profundidade da árvore. A Tabela 5 mostra os valores utilizados para a profundidade da árvore no algoritmo de árvore de decisão e os outros valores de parâmetros utilizados.

Árvore de decisão
Profundidade máxima da árvore = 2, 3, 5, 7, 10, 12
Mínimo de amostras no nó folha = 1
Mínimo de amostras no nó interno = 2

**Tabela 5. Valores dos hiperparâmetros utilizados para os modelos de árvores de decisão.**

No processo de escolha dos hiperparâmetros, foi utilizada a validação cruzada com *k-folds* sendo  $k=5$ . O conjunto de dados utilizado é o conjunto de treino que foi separado do conjunto gerado pelo modelo analítico. Observe na Figura 2 o exemplo de uma interação da validação cruzada, com a divisão do treino em treino e validação.

O treinamento dos modelos ocorreu de forma separada para cada variável de saída, que são 5 no total. Ou seja, foram criados 5 modelos de regressão linear, uma para cada variável de saída e 30 modelos de árvore de decisão (6 variações de hiperparâmetros para cada uma das 5 variáveis de saída).

### 3.2. Avaliação dos Modelos

Para avaliar os modelos, foram utilizadas as seguintes métricas:

- $R^2$  (Coeficiente de Determinação):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

- MAE (Erro Médio Absoluto):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- MAPE (Mean absolute percentage error):

$$ErroPercentual = \frac{1}{n} \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \times 100\%$$

onde:  $n$  é o número de amostras nos dados de teste,  $y_i$  são os valores reais da variável de saída,  $\hat{y}_i$  são as previsões do modelo e  $\bar{y}$  é a média dos valores reais. O valor de  $R^2$  mede a proporção da variância total dos dados de saída que é explicada pelo modelo e quanto mais próximo de 1 melhor. A métrica MAE tem a mesma unidade da variável de saída e medem o erro do modelo. A métrica MAPE mostra a porcentagem de erro em relação aos valores reais. Quanto menor o MAPE, melhor o modelo se ajusta um conjunto de dados.

Além dessas métricas, as curvas de complexidade do modelo podem ser visualizadas para verificar o desempenho em função da complexidade do modelo, por exemplo, em função do número de árvores do modelo de árvore de decisão.

## 4. Resultados

Nessa seção são apresentados os resultados obtidos no treinamento do modelo de regressão linear e de árvore de decisão para cada uma das cinco propriedades elásticas das lâminas para o conjunto de dados gerado pelo modelo analítico de homogeneização assintótica. Os resultados obtidos no teste dos modelos é apresentado para o conjunto de dados de teste gerado pelo modelo analítico e o conjunto de dados experimentais gerado em laboratório.

### 4.1. Desempenho no treinamento

O treinamento do modelo foi realizado utilizando o conjunto de dados gerado pelo modelo analítico de homogeneização assintótica. A Tabela 6 apresenta os valores das métricas de avaliação para regressão linear. O resultado foi superior a 0.75 para todas a propriedades elásticas da lâmina e o melhor resultado obtido foi para a propriedade E1, que representa o módulo de elasticidade longitudinal, com valor 0.94 para o  $R^2$ .

**Tabela 6. Resultado das métricas de avaliação para o treinamento dos modelos de Regressão Linear.**

Propriedade	$R^2$	MAE
E1	0.9392(0.0005)	12.1267 (0.0353)
E2	0.7937 (0.002)	2.4198 (0.0086)
G12	0.8581(0.001)	0.7972(0.0029)
G23	0.7553(0.0017)	1.0696(0.0048)
nu12	0.9225(0.001)	0.0074(0.001)

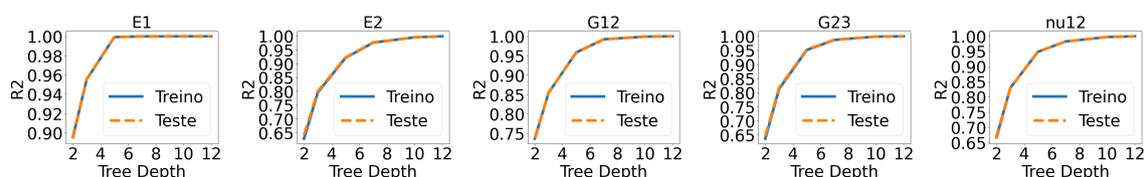
A Tabela 7 apresenta o resultado do treinamento para cada propriedade e variando o hiperparâmetro de profundidade máxima da árvore de decisão. Foi treinado um modelo

para cada propriedade da lâmina do compósito. A propriedade E1 apresenta valores bem próximos de um já com profundidade máxima igual a sete. Para as outras propriedades, o valor de  $R^2$  continua aumentando com o aumento da profundidade máxima da árvore. O valor de profundidade máxima da árvore escolhido para realizar o teste dos modelos criados foi doze.

**Tabela 7. Valores de  $R^2$  para o treinamento do modelo de árvore de decisão variando o hiperparâmetro de profundidade máxima da árvore.**

Profundidade	E1	E2	G12	G23	nu12
3	0.9553	0.7966	0.8548	0.8142	0.8291
5	0.9992	0.9210	0.9577	0.9514	0.9479
7	0.9999	0.9757	0.9920	0.9870	0.9819
10	1.0000	0.9950	0.9990	0.9987	0.9967
12	1.0000	0.9987	0.9998	0.9997	0.9992

A Figura 3 mostra as curvas de complexidade para os modelos de cada propriedade da lâmina. É possível observar como o valor de  $R^2$  é afetado pela complexidade do modelo, nesse caso, pelo valor da profundidade máxima da árvore de decisão. É importante observar essa curva, pois ela nos permite identificar o ponto de ajuste do hiperparâmetro que maximiza o desempenho do modelo no conjunto de teste para evitar o superajuste (*overfitting*) do modelo, [Géron 2019]. Observe que para todas as propriedades as curvas de treino e teste apresentam um comportamento semelhante, mostrando que o modelo não se sobreajusta para o treino e consegue prevê com excelente valor para  $R^2$  também no teste.



**Figura 3. Complexidade Árvores de Decisão.**

## 4.2. Avaliação dos modelos

Após o treinamento dos modelos, a avaliação é feita utilizando dois conjuntos de teste, o conjunto gerado pelo modelo analítico e o conjunto de dados experimentais gerados em laboratório. Esses valores são comparados também com valores gerados pelo modelo analítico.

O resultado obtido com o conjunto de teste para os modelos de regressão linear são apresentados na Tabela 8. Para o conjunto de dados gerado pelo modelo analítico o valor de  $R^2$  foi superior a 0.74 para todos os modelos e a propriedade que apresentou maior valor foi E1. A propriedade que apresentou menor erro percentual foi a nu12, 2.47% e o valor de  $R^2$  igual a 0.92. Para o conjunto de dados experimentais a melhor estimativa foi para a métrica E1, com o valor de 96%.

**Tabela 8. Métricas de avaliação para a previsão dos valores das propriedades geradas pelo modelo de regressão linear para os dois conjuntos de teste.**

Conjunto Dados	Métricas	E1	E2	G12	G23	nu12
Modelo Analítico	$R^2$	0.94	0.79	0.86	0.75	0.92
	MAE	11.9797	2.43	0.7990	1.07525	0.00733
	MAPE	20.8%	33.69%	32.03%	40.47%	2.47%
Experimentais	$R^2$	0.96	0.60	0.56	0.34	-0.52
	MAE	8.1282	1.8663	0.7648	0.7906	0.04697
	MAPE	8.68%	17.02%	14.10%	23.05%	14.87%

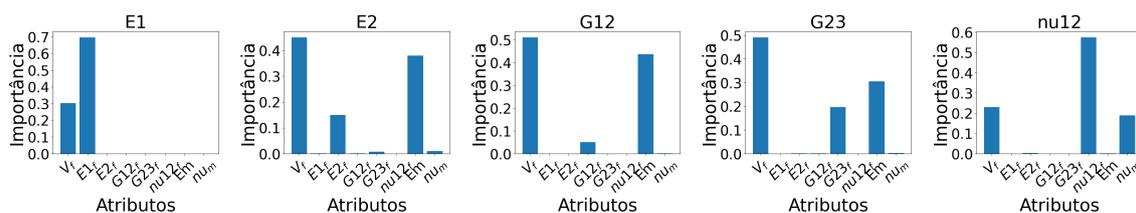
A Tabela 9 apresenta o resultado obtido para os modelos de árvore de decisão que foram gerados. Observe que as métricas obtidas para o conjunto de teste do conjunto de dados do modelo analítico são todos com  $R^2$  igual a 1.0 e erro percentual mínimo. Para os dados experimentais o desempenho foi muito bom para as métricas E1 e G23. Para as outras métricas, E2, G12 e nu12 o erro percentual foi de aproximadamente 15.9%.

**Tabela 9. Métricas de avaliação para a previsão dos valores das propriedades geradas pelo modelo de árvore de decisão para os dois conjuntos de teste. A profundidade máxima da árvore é doze.**

Conjunto Dados	Métricas	E1	E2	G12	G23	nu12
Modelo Analítico	$R^2$	1.00	1.00	1.00	1.00	1.00
	MAE	0.0045	0.1207	0.0162	0.0212	0.0006
	MAPE	0.01%	0.85%	0.29%	0.32%	0.21%
Experimentais	$R^2$	0.93	0.48	0.24	0.83	-0.59
	MAE	8.2129	2.0941	0.9383	0.4461	0.0488
	MAPE	6.99%	17.69%	15.24%	13.82%	15.86%

### 4.3. Importância das características e estudo visual do modelo

Após treinar a árvore de decisão, é possível acessar as pontuações de importância das características que medem quanto cada recurso contribuiu para a redução da impureza nas divisões da árvore e conseqüentemente contribuiu para a estimativa do valor alvo. Na Figura 4 é possível visualizar a importância das características para o melhor modelo de cada uma das propriedades. Observe que para a propriedade E1 as características que mais contribuem são  $E1_f$  e  $V_f$ , já para E2 são  $V_f$ ,  $E_m$  e  $E2_f$ , para G12 são  $V_f$ ,  $E_m$  e  $G12_f$ , para G23 são  $V_f$ ,  $E_m$  e  $G23_f$  e para nu12 são  $nu12_f$ ,  $V_f$  e  $nu_m$ .



**Figura 4. Importância das características do melhor modelo de árvores de decisão para cada uma das propriedades.**

Um estudo visual do modelo pode ser feito também por meio das regras geradas para cada um dos modelos em forma de árvore. As Figuras 5 e 6 mostram as regras geradas para os modelos que preveem as propriedades E1 e E2 respectivamente. Observe que as características que são avaliadas seguem a ordem das características que tem maior importância.

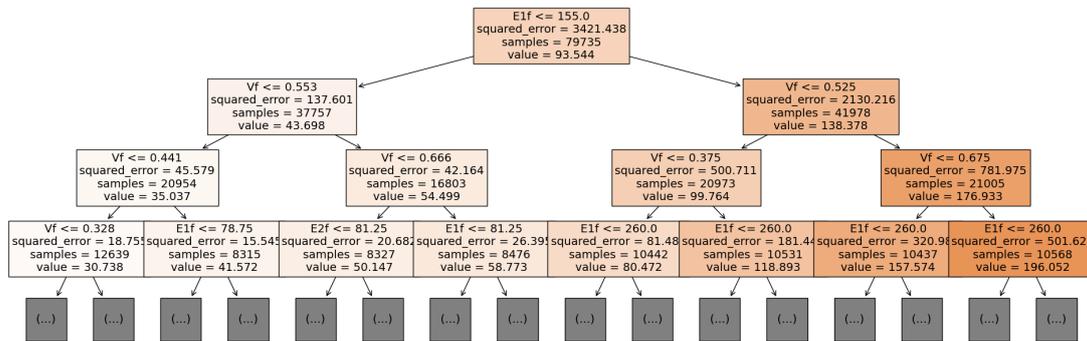


Figura 5. Visualização da árvore de decisão gerada para previsão da propriedade E1.

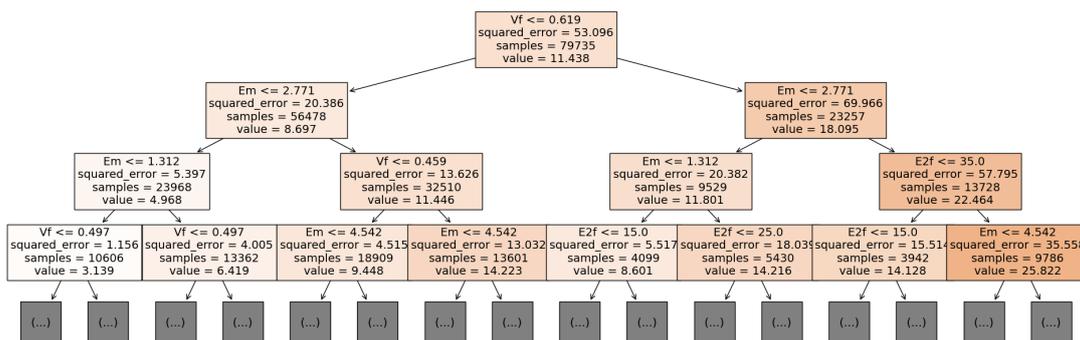


Figura 6. Visualização da árvore de decisão gerada para previsão da propriedade E2.

## 5. Conclusão

Esse trabalho apresentou uma abordagem para previsão das propriedades micromecânicas de lâminas de compósitos utilizando apresentado de máquina visando economia de tempo e custo em relação às abordagens tradicionais. Dois conjuntos de dados foram utilizados nos experimentos e os modelos utilizados foram os de regressão linear e árvores de decisão.

Ao realizar o teste dos dados gerados, observou-se que a regressão linear não conseguiu aprender de maneira satisfatória a reprodução do método da homogeneização assintótica, por resultar em elevados erros. Por outro lado, o métodos de árvore de decisão apresentou  $R^2$  elevado nos treinamentos e teste, além de erros próximos a zero nos testes no conjunto de dados gerado pelo modelo de dados analítico. Já a análise do desempenho das estimativas comparadas com os dados de laboratório, todos os modelos de treinamento obtiveram erros semelhantes.

Com maior volume de dados experimentais disponíveis, um trabalho interessante a ser feito é o treinamento e o teste exclusivamente com os mesmos. Visto que os modelos estão limitados a aprender o que os dados contêm, a utilização de dados experimentais possibilitaria a superioridade do desempenho do modelo de aprendizado de máquina frente aos métodos analíticos, ampliando as vantagens dos mesmos em reduzir a quantidade de linhas ao programar cada método, visto a quantidade de equações utilizadas na homogeneização assintótica, e possivelmente alcançar melhor desempenho. Já em relação aos ensaios experimentais, os benefícios se mostram na redução tanto do tempo quanto dos custos.

## Referências

- Benzarti, K., Cangemi, L., and Dal Maso, F. (2001). Transverse properties of unidirectional glass/epoxy composites: influence of fibre surface treatments. *Composites Part A: Applied Science and Manufacturing*, 32(2):197–206.
- Bledzki, A., Kessler, A., Rikards, R., and Chate, A. (1999). Determination of elastic constants of glass/epoxy unidirectional laminates by the vibration testing of plates. *Composites Science and Technology*, 59(13):2015–2024.
- Bravo-Castillero, J., Guinovart-Díaz, R., Rodríguez-Ramos, R., Sabina, F. J., and Brenner, R. (2012). Unified analytical formulae for the effective properties of periodic fibrous composites. *Materials Letters*, 73:68–71.
- Camanho, P., Maimí, P., and Dávila, C. (2007). Prediction of size effects in notched laminates using continuum damage mechanics. *Composites Science and Technology*, 67(13):2715–2727.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media.
- Guo, P., Meng, W., Xu, M., Li, V. C., and Bao, Y. (2021). Predicting mechanical properties of high-performance fiber-reinforced cementitious composites by integrating micromechanics and machine learning. *Materials*, 14(12):3143.
- Huang, H. and Talreja, R. (2005). Effects of void geometry on elastic properties of unidirectional fiber reinforced composites. *Composites Science and Technology*, 65(13):1964–1981.
- Huang, Z.-m. (2001). Micromechanical prediction of ultimate strength of transversely isotropic fibrous composites. *International journal of solids and structures*, 38(22-23):4147–4172.
- Kaddour, A. and Hinton, M. (2012). Input data for test cases used in benchmarking triaxial failure theories of composites. *Journal of Composite Materials*, 46(19-20):2295–2312.
- Kaddour, A., Hinton, M., Smith, P., and Li, S. (2013). The background to the third world-wide failure exercise. *Journal of Composite Materials*, 47(20-21):2417–2426.
- Kriz, R. and Stinchcomb, W. (1979). Elastic moduli of transversely isotropic graphite fibers and their composites. *Experimental Mechanics*, 19(2):41–49.
- Lee, J. and Soutis, C. (2007). A study on the compressive strength of thick carbon fibre–epoxy laminates. *Composites Science and Technology*, 67(10):2015–2026.

- Li, W., Cai, H., and Zheng, J. (2014). Characterization of strength of carbon fiber reinforced polymer composite based on micromechanics. *Polymers and Polymer Composites*, 22(2):105–116.
- Merayo, D., Rodríguez-Prieto, A., and Camacho, A. M. (2020). Prediction of physical and mechanical properties for metallic materials selection using big data and artificial neural networks. *IEEE Access*, 8:13444–13456.
- Pathan, M., Ponnusami, S., Pathan, J., Pitisongsawat, R., Erice, B., Petrinic, N., and Tagarielli, V. (2019). Predictions of the mechanical properties of unidirectional fibre composites by supervised machine learning. *Scientific reports*, 9(1):1–10.
- Rajput, R., Raut, A., and Setti, S. G. (2022). Prediction of mechanical properties of aluminium metal matrix hybrid composites synthesized using stir casting process by machine learning. *Materials Today: Proceedings*, 59:1735–1742.
- Schaefer, J., Werner, B., and Daniel, I. M. (2014). Strain-rate-dependent failure of a toughened matrix composite. *Experimental Mechanics*, 54(6):1111–1120.
- Shahinur, S. and Hasan, M. (2020). Natural fiber and synthetic fiber composites: Comparison of properties, performance, cost and environmental benefits.
- Soden, P., Hinton, M., and Kaddour, A. (1998). Lamina properties, lay-up configurations and loading conditions for a range of fibre-reinforced composite laminates. *Composites Science and Technology*, 58(7):1011–1022.
- Tsai, S. and Hahn, H. (1980). Introduction to composite materials, technomic publ. Co., Westport.
- Ventura, A. M. F. (2009). Os compósitos e a sua aplicação na reabilitação de estruturas metálicas. *Ciência & Tecnologia dos Materiais*, 21(3-4):10–19.
- Vignoli, L. L., Savi, M. A., Pacheco, P. M., and Kalamkarov, A. L. (2019). Comparative analysis of micromechanical models for the elastic composite laminae. *Composites Part B: Engineering*, 174:106961.
- Wang, W., Wang, H., Zhou, J., Fan, H., and Liu, X. (2021). Machine learning prediction of mechanical properties of braided-textile reinforced tubular structures. *Materials & Design*, 212:110181.
- Yim, J. H. and Gillespie Jr, J. (2000). Damping characteristics of 0° and 90° as4/3501-6 unidirectional laminates including the transverse shear effect. *Composite Structures*, 50(3):217–225.