

PREVISÃO DE PROPRIEDADES MECÂNICAS DE COMPÓSITOS TRANÇADOS ATRAVÉS DE REDES NEURAIS DO TIPO RNAs

Luzayamo V A Jorge (IC)¹, Renata Neves Penha (PQ)¹
¹(Universidade federal de Itajubá – UNIFEI)

Palavras-chave: Compósito de fios trançados. Fibra de vidro. Kevlar 49. Fibra de carbono

Introdução

Nos dias de hoje os materiais compósitos estão sistematicamente substituindo outros tipos de materiais convencionais, desde a fabricação de objetos de uso corriqueiro à componentes para indústrias específicas, e em aplicações estruturais. De forma genérica, um compósito pode ser definido como qualquer substância composta por várias fases que apresenta uma proporção substancial das características de ambas as fases que o compõem. (CALLISTER, 2007).

Atualmente ocupam um lugar de destaque nos projetos de engenharia. Devido à vantagem que possuem em relação aos materiais tradicionais, entre os quais se destacam a facilidade de processamento, a elevada rigidez, resistência mecânica e o baixo peso específico (MARCELO, 2005).

Os compósitos estão classificados em três divisões principais: os reforçados com partículas, os estruturais e os reforçados com fibras, que por sua vez podem ser curtas ou contínuas. O arranjo ou a orientação das fibras contínuas umas em relação às outras, o ângulo de entrelaçamento, a concentração das fibras e sua distribuição possuem uma influência significativa sobre a resistência.

Compósitos de fios trançados são aqueles nos quais a matriz é fortalecida com fios contínuos entrelaçados em um padrão de trança. Esses fios são tipicamente fabricados a partir de materiais como fibra de vidro, carbono ou aramida, e são integrados na matriz com o propósito de aprimorar as características mecânicas e estruturais do compósito. A configuração entrelaçada dos fios oferece uma resistência extra ao material.

Segundo Carey, J 2016 novas demandas por fabricação de materiais compósitos de alta qualidade em altas taxas de produção têm focado a atenção nos compósitos

trançados. O comportamento mecânico desses materiais pode ser abordado através de parâmetros como comportamento elástico, plástico e de falha: resistência final e os mecanismos de falha.

Redes neurais artificiais (RNAs) é um conjunto de unidades de processamento interconectadas usadas para realizar tarefas específicas, assim como outros modelos computacionais, utilizam conceitos matemáticos para fazer previsões.

Deste modo, o presente trabalho tem como objetivo, criar um modelo matemático capaz de prever propriedades mecânicas de compósitos de fios trançados com base nos critérios de entrada estabelecidos posteriormente.

Para este trabalho foram considerados os compósitos: Fibra de vidro, fibra de carbono e kevlar 49.

Metodologia

A arquitetura do algoritmo usado é composta por dados de entrada; neurônios; com conexões entre eles onde cada uma delas possui peso sináptico, bias; com valor aplicado externamente a cada neurônio, tem como efeito de aumentar ou diminuir a entrada da função de ativação, função de ativação; restringe a amplitude do valor de saída de um neurônio e dados de saída (HAYKIN, 2008).

A principal propriedade de uma rede neural artificial é a capacidade de aprender por meio de exemplos e fazer implicações, as redes neurais usam um algoritmo de aprendizagem cujo objetivo é ajustar os pesos de suas conexões (BRAGA; CARVALHO; LUDEMIR, 2000).

Para se obter resultados significativos e relevantes sobre arquitetura da rede neural escolhida, partiu-se da inserção de dados provenientes de uma revisão bibliográfica, onde estudos mostraram que o ângulo de tranças influencia a resistência e a rigidez dos compósitos trançados (PHOENIX, 1978). Logo, como dados de entrada foram

selecionados os seguintes critérios: Ângulo da trança, diâmetro das fibras e sua densidade específica com os devidos valores apresentados na Tabela 1. Foi estabelecido valores iguais para os ângulos em ambos materiais de modo a estabelecer um padrão, embora os diâmetros e a densidade variem o que depende especificamente do meio de fabricação e propriedades intrínseca de cada material.

Tabela 1 – Parâmetros de entrada na rede, *Inputs*.

| Dados de entrada | | | |
|------------------|-------------------|---------------|--------------------------------|
| Material | Ângulo (°) | Diâmetro (mm) | Densidade (g/cm ³) |
| Fibra de vidro | 20,1° - 45° - 90° | 0,02 - 0,005 | 1,9 - 2,47 |
| Fibra de carbono | | 0,01 - 0,007 | 1,70 - 1,75 |
| Kevlar 49 | | 0,02 - 0,01 | 1,09 - 1,45 |

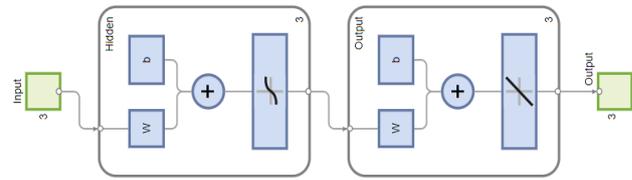
Fonte: Própria autoria

Para os dados de saída a rede é alimentada de modo que possa prever três variáveis de saída: limite de escoamento, compressão e módulo de Young para a fibra de vidro, limite de escoamento, compressão e tensão de cisalhamento para a fibra de vidro e limite de escoamento, compressão, e módulo de cisalhamento para o kevlar 49. (ABBAS, A; GARRETT, M, 2021, BANDARU, A; MITTAL, K; CHOUHAN, H; ASIJA, N; BHATNAGAR, N; AHMAD, S, 2017, DONG J; HUO N, 2016, SUN X; SUN C, 2004, FANGUEIRO, R; GONILHO PEREIRA, C; DE ARAÚJO, M; JALALI, S, LI Dian; LU Zi-xing; LI Chen, 2023, LI Dian; Xueyang, Z; JIANG L, FANG D, 2023).

Os dados usados no treinamento, Validação e testes foram baseados em artigos científicos com diferentes metodologias de diferentes grupos de pesquisa, que configuraram uma base de dados com propriedades mecânicas relacionados aos dados de saída do interesse do presente trabalho.

As simulações foram feitas utilizando o *toolbox* de RNAs do *software* MatLab® 2023. A estrutura geral da rede selecionada foi: Três dados de entrada, três camadas ocultas, três dados de saída, como mostra a Figura 1. A função de ativação utilizada foi a tangente sigmoideal e variou-se o número de neurônios na camada intermediária entre 3 e 10.

Figura 1 – Forma esquemática estrutural da rede utilizada.



Fonte: Matlab® 2023.

Durante o processo de treinamento, o programa avalia a função objetivo, que neste estudo envolveu o cálculo da diferença quadrática entre os resultados experimentais e os estimados pela RNA, para os três conjuntos de dados. Um dos critérios de término para o algoritmo foi o limite de iterações, também conhecido como número de épocas. O critério principal foi calculado através da função da Tangente hiperbólica (Tan h).

Observando os valores gerados pela a funções Tan h na Tabela 2, pode verifica-se que o algoritmo utilizado na rede neural, após treinamento e validação obteve resultados satisfatórios nos testes para os três tipos de compósito.

Tabela 2 – Valores obtidos para Tan h.

| Material | Tan h |
|------------------|----------|
| Fibra de vidro | 0,987824 |
| Fibra de carbono | 1 |
| Kevlar 49 | 1 |

Fonte: Própria autoria

Por fim, foram comparados os resultados gerados pela RNA com os dados experimentais coletados e então calculados os erros para cada variável de saída.

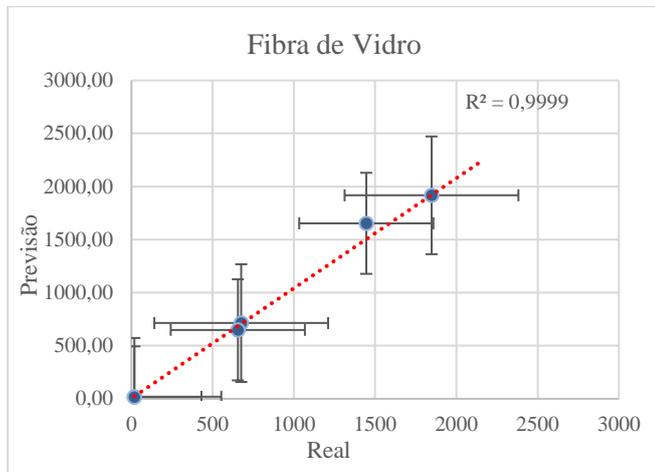
A fim de comparar os dados previstos e reais recorre-se a ferramentas estatística como coeficiente de Correlação de Pearson (r^2) para avaliar a relação linear entre as duas variáveis.

Resultados e discussão

Os resultados obtidos correlacionando os valores retornado pela rede versus valores experimentais, *outputs*, são mostradas nas Figuras 2 para a fibra de vidro, Figura 3 para fibra de carbono e Figura 4 para o Kevlar 49. É possível verificar uma aproximação aceitável, tendo em conta os parâmetros usados pelo coeficiente de correlação, que devem variar entre de -1 a 1.

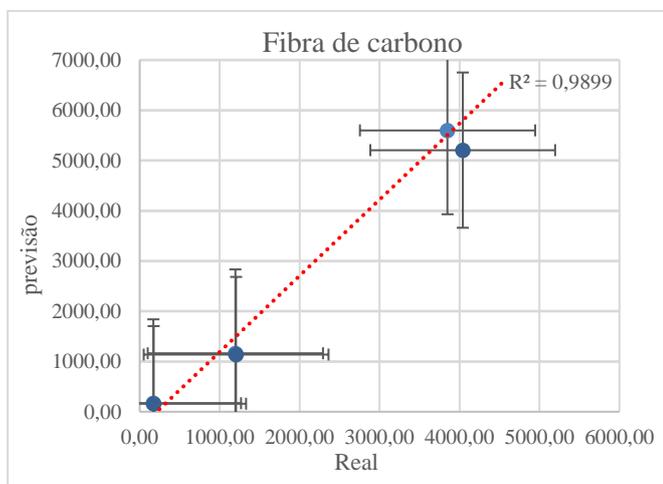
Figura 2 – Comparação de valores obtidos pela rede

versus valores reais de ensaios mecânicos para a fibra de vidro.



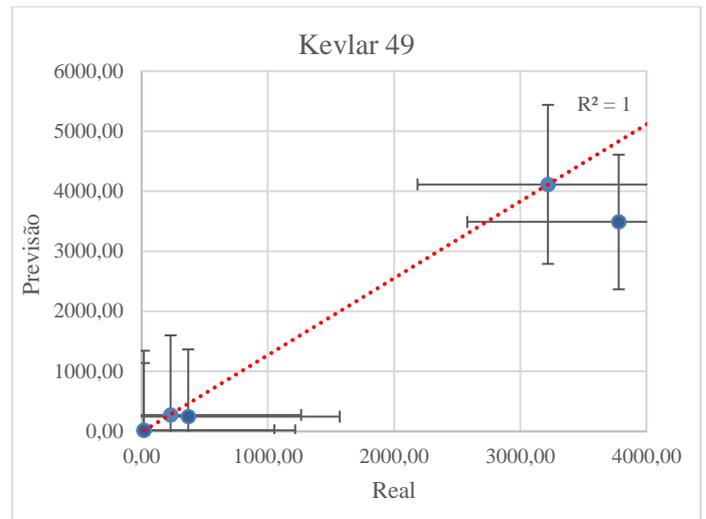
Fonte: Própria autoria

Figura 3 – Comparação de valores obtidos pela rede versus valores reais de ensaios mecânicos para a fibra de carbono.



Fonte: Própria autoria

Figura 4 – Comparação de valores obtidos pela rede versus valores reais de ensaios mecânicos para kevlar 49.



Fonte: Própria autoria

Para alguns resultados houve um certo distanciamento entre os pontos nos gráficos, isso deve-se a escassez de dados durante a revisão bibliográfica e a dificuldade de relacioná-los, já que cada trabalho referenciado tem objetivos, metodologia, e executadas por pessoas distintas.

Conclusões

Concluimos que as redes neurais são ferramentas poderosas e precisas, diminuem consideravelmente fontes de erros e podem ser usadas para prever antecipadamente resultados que podem ser confirmados em laboratório.

Agradecimentos

Agradeço ao pai celestial DEUS todo poderoso pelo sopro de vida, por me sustentar, capacitar e conceder sabedoria ao longo da realização e finalização desse trabalho.

Agradeço os meus pais pelo amor, força, suporte e por acreditarem em mim.

Agradeço ao meu irmão Luvuvamo Jorge Carlos pelo suporte.

Agradeço aos meus amigos da Republica Xumingo, pelo suporte e tornar essa jornada mais leve e única.

Agradeço a minha orientadora Professora Dr. Renata Neves Penha pela orientação, compreensão e voto de confiança depositado na minha pessoa.

Agradeço à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pela bolsa concedida em

todo o período do trabalho permitindo que eu cursasse esta etapa.

Agradeço à Universidade Federal de Itajubá (UNIFEI) pelo ambiente e a oportunidade de eu possuir um ensino superior.

Agradeço a todos que direta ou indiretamente contribuíram para a conclusão deste trabalho.

Referências

ABBAS, A; GARRETT, M. **Experimental evaluation of carbon fibre, fibreglass and aramid tubular braided composites under combined tension-torsion loading.** Composite Structures, 2021. 114049 p. v. 269.

BANDARU, A; MITTAL, K; CHOUHAN, H; ASIJA, N; BHATNAGAR, N; AHMAD, S. **Characterization of 3d angle-interlock thermoplastic composites under high strain rate compression loadings.** New Delhi: Polymer Testing, 2017. 355-365 p. v. 62.

BRAGA, A; LUDERMIR, T; CARVALHO, A. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro: LTC. Acesso em: 15 set. 2023, 2000.

CALLISTER, W. D., **Ciência e Engenharia de Materiais: Uma Introdução.** 7.ed, John Wiley & Sons, Inc., 2017.

CAREY, J. **Handbook of Advances in Braided Composite Materials: Theory, Production, Testing and Applications.** 2016.

DONG J; HUO N. **A two-scale method for predicting the mechanical properties of 3D braided composites with internal defects:** Composite Structures, 2016. 1-10 p. v. 152.

FANGUEIRO, R; GONILHO PEREIRA, C; DE ARAÚJO, M; JALALI, S **Propriedades mecânicas do reforçado trançado compósitos**

FERREIRA. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro: LTC. Acesso em: 13 set. 2023, 2000.

HAYKIN, S. **Neural Networks: Neural Networks and Learning Machines Third Edition,** 2008.

LI Dian; LU Zi-xing; LI Chen; LI Jia Lu. **Microstructure and mechanical properties of three-dimensional five-directional braided.** International.

Journal of Solids and Structures, 2009. 3422-3432 p. v. 46.

LI Dian-sen; Xueyang, ZHU H; JIANG Lei, FANG Daining. **Unit-cell geometry and mechanical properties of three-dimensional seven-directional braided composites.** Thin-Walled Structures, 2023. 110-299 p. v. 182.

MARCELO F; ALFREDO B; ANTÔNIO G. **Materiais Compósitos Materiais, Fabrico e Comportamento Mecânico.** 2.ed, 2005.

PHOENIX SL. **Mechanical Response of a Tubular Braided Cable with an Elastic Core.** Textile Research Journal. 1978.

SUN X; SUN C. **Mechanical properties of three-dimensional braided composites.** 3. ed. Local: Composite Structures, 2004. 485-492 p. v. 65.

YUTONG, F; XUEFENG, Y; XUHAO G. **Prediction of mechanical properties in 3D braided composites with void defects,** Composites Part A: Applied Science and Manufacturing, 2021. 106-450 p. v. 147.