

Aplicação de Redes Neurais para Simulação do Comportamento em Cisalhamento de Compósitos Matriz Epóxi Reforçados com Fibras de Carbono

E.M. Bezerra, A. C. Ancelotti, L.C. Pardini, K. Iha, J.A. F. F. Rocco
Instituto Tecnológico de Aeronáutica, Departamento de Química, Praça Marechal
Eduardo Gomes 50 Vila das Acácias, 12228-900 São José dos Campos, SP, Brasil
edumarcelo@superig.com.br

RESUMO

Inspirado em um sistema nervoso biológico, as redes neurais artificiais (RNAs) têm sido utilizadas como uma das principais ferramentas para classificação de dados e reconhecimento de padrões. Redes neurais artificiais são utilizadas em aplicações médicas; reconhecimento de imagens e controle de sistemas dinâmicos, mas apenas recentemente estão sendo empregadas na predição do comportamento mecânico de materiais compósitos. Neste trabalho, as redes foram consideradas especificamente para simular o comportamento em cisalhamento de compósitos resina epóxi reforçados com 58% em volume de fibras de carbono. Uma rede neural perceptron multicamadas (MLP) foi utilizada, e os resultados mostraram que a aplicação do algoritmo de aprendizado Levenberg-Marquardt conduziu a uma alta qualidade preditiva, uma vez que 71% dos coeficientes de determinação R^2 situaram-se acima de 0.95. A utilização de redes neurais conduziu a um ajustamento preciso das curvas de cisalhamento comparativamente à técnica de regressão polinomial em decorrência da característica não-linear destas curvas.

Palavras-chave: redes neurais artificiais, regressão, compósitos, carbono.

1. INTRODUÇÃO

Os compósitos estruturais são materiais de uso constante na indústria aeronáutica devido às suas propriedades mecânicas equivalentes ou superiores aos materiais isotrópicos metálicos aliados a baixa massa específica. Para uso em situações que demandem requisitos estruturais é necessário assegurar a garantia de

propriedades mecânicas. A utilização das redes neurais pode otimizar a formulação destes compósitos através da estimativa de seu comportamento mecânico ^[1]. Uma das propriedades de interesse desses materiais é o comportamento em cisalhamento visto que a resistência nesse quesito é no mínimo cinco vezes a resistência no plano de reforço. O modelamento matemático do comportamento em cisalhamento deve ser obtido a partir dos dados experimentais ^[2]. Uma vez estabelecido o modelo, o trabalho experimental envolvido no desenvolvimento de novas formulações pode ser reduzido drasticamente. As redes neurais permitem, através de um banco de dados adequado, a predição do comportamento mecânico dos compósitos de matriz polimérica reforçados, entretanto não possibilitam o entendimento do mecanismo de falha, uma vez que sua estruturação é feita com base apenas nos dados experimentais ^[2]. O comportamento mecânico de compósitos de matriz epóxi reforçados com fibras de carbono está associado a vários fatores^[3], dentre os quais destacam-se: (1) fração volumétrica de reforço, (2) disposição das camadas e orientação, (3) interface e adesão e as (4) propriedades mecânicas intrínsecas das fibras ^[3,4].

Além dos fatores acima citados há que se considerar os custos intrínsecos e os custos associados aos ensaios mecânicos. Desta forma, a otimização dos testes através de um planejamento estatístico adequado é de fundamental importância; relacionando-se à confiabilidade das estruturas aeronáuticas submetidas às várias solicitações mecânicas durante sua utilização em condições de operação. Dentre os testes mecânicos, as medidas de resistência ao cisalhamento e à compressão são sensíveis à interação entre as fibras e a matriz ^[4]. Os compósitos submetidos à tensões de cisalhamento apresentam um comportamento não-linear para as curvas de tensão em função da deformação. Tal comportamento traz consigo uma dificuldade inerente associada à modelagem destas curvas e predição de seu comportamento para os diferentes parâmetros de entrada a serem considerados ^[5-6].

Recentemente, as redes neurais artificiais (RNAs) estão sendo consideradas o estado da arte para modelagem e predição do comportamento de sistemas não-lineares ^[7-8]. Através de inúmeras aplicações ^[7-9] constatou-se que as redes neurais são uma ferramenta computacional eficiente para o modelamento e predição das propriedades mecânicas dos materiais compósitos. Apesar de sua analogia com a estrutura biológica, as redes aprendem a partir de exemplos em um processo cognitivo. Desta forma, as redes são treinadas a partir de exemplos constituídos por

suas unidades de entrada e saída, estabelecendo-se uma correlação não-linear e multidimensional entre as unidades apresentadas ^[10]. Assim, as redes são definidas como modelos computacionais análogos ao sistema nervoso biológico e construídas a partir de um conjunto de dados interconectados entre suas diversas camadas ^[10]. Neste trabalho foi empregado o modelo perceptron multicamadas. Neste modelo, os neurônios são dispostos em três camadas interconectadas: entrada, camadas escondida e de saída. A relação não-linear entre os dados de entrada e saída é calculada através de matrizes compostas de neurônios (matriz de pesos) presentes entre as camadas de entrada e escondida e entre esta e a camada de saída. Desta forma, os pesos foram calculados e recalculados através do algoritmo computacional de convergência rápida – Levenberg-Marquardt – buscando-se reduzir o erro quadrático médio entre a saída da rede e a saída desejada ^[11].

Para a realização deste processo, uma base de dados considerável foi empregada para desenvolver uma rede de alto desempenho e confiabilidade, incluindo sua arquitetura, funções de treinamento, algoritmos de treinamento e outros parâmetros relevantes ^[12-13]. O objetivo deste trabalho é mostrar a possibilidade de utilizar-se redes neurais para predição do comportamento de compósitos epóxi-carbono submetidos ao ensaio de cisalhamento losipescu. As curvas de tensão versus deformação geradas a partir deste ensaio são tipicamente não-lineares, uma vez que este comportamento está relacionado às propriedades interfaciais. A arquitetura e o treinamento da rede foram realizados utilizando-se como suporte o tutorial de redes neurais que faz parte do software Matlab ^[14].

2. MATERIAIS E MÉTODOS

2.1 Materiais

Utilizou-se um pré-impregnado de fibras de carbono em resina epóxi com especificação F155. O pré-impregnado é composto tecido 5HS (harness satin), conforme mostra a Figura 1, e foi fornecido pela Hexcel Co. , onde a urdidura (urdume) passa sobreposto à 4 cabos da trama. Esse tipo de tecido é largamente empregado pela indústria aeronáutica.




Figura 1 – Representação do tecido 5 HS

2.2 Processamento dos Compósitos

Os compósitos de fibras de carbono/epóxi foram preparados pelo empilhamento de 10 camadas apresentando 55% em fração volumétrica de fibras. As camadas de pré-impregnados foram empilhadas e seladas em uma bolsa de vácuo ^[10]. A cura foi executada em autoclave. O ciclo de cura foi realizado com uma taxa de aquecimento de 2.5°C/min até a temperatura final de 120°C, permanecendo à essa temperatura durante 1 hora. A pressão do sistema e a de vácuo foram 0.69MPa e 0.083MPa, respectivamente.

2.3 Cisalhamento Iosipescu

O ensaio de cisalhamento Iosipescu foi utilizado para medida da tensão de cisalhamento e módulo em cisalhamento. A representação do ensaio é mostrada na Figura 2. A área quadrada coberta pelos sensores de deformação (strain gages) é referida como a região de teste neste estudo, localizados à $\pm 45^\circ$ em relação à linha média do comprimento. Os raios das pontas do entalhe medem 1.3 mm. A espessura média das amostras ensaiadas é de (2.1 ± 0.2) mm. A amostra é colocada em um dispositivo fixo e a região entre entalhes é a linha de aplicação de carga por meio de um alinhamento entre a ferramenta e o dispositivo. A utilização de entalhes se justifica porque provoca uma distribuição mais uniforme de tensões comparativamente às amostras sem entalhes. Pela aplicação de dois conjuntos de força que geram dois momentos de ação contrários; um estado de cisalhamento puro e uniforme é gerado na seção central (Figura 3). Os diagramas de cisalhamento e do momento fletor são mostrados esquematicamente na Figura 3.




Figura 2 . Esquematização do Ensaio Iosipescu: a) Dispositivo Iosipescu; b) Configuração da Amostra

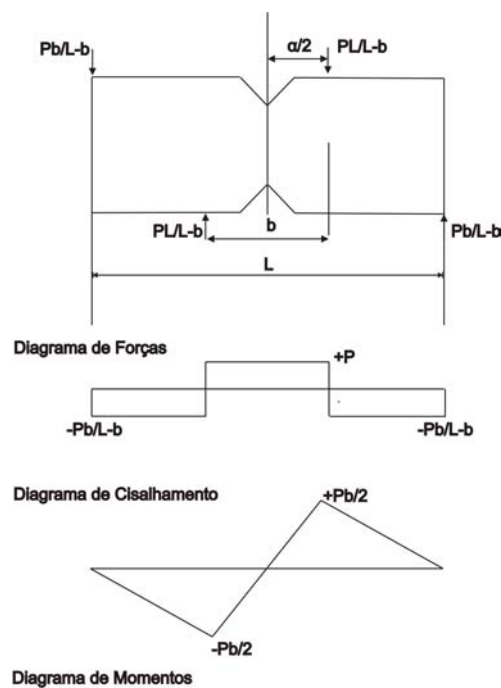


Figura 3 – Diagramas de força, cisalhamento e momento fletor para o ensaio Iosipescu.

A deformação em cisalhamento é obtida pela soma dos módulos das deformações medidas, conforme equação 1.

$$\gamma_i = |\varepsilon_{+45}| + |\varepsilon_{-45}| \quad (1)$$

sendo:

γ_i = deformação em cisalhamento no i-ésimo ponto, $\mu\varepsilon$;

ε_{+45} = +45° normal à deformação no i-ésimo ponto, $\mu\varepsilon$; e

ε_{-45} = -45° normal à deformação no i-ésimo ponto, $\mu\varepsilon$

O módulo de cisalhamento pode ser obtido pela tensão de cisalhamento e deformação em cisalhamento correspondente assegurando-se que a tensão e a deformação são uniformemente distribuídas na região elástica dessa curva.

Os ensaios de cisalhamento foram realizados em concordância com a norma ASTM D-5379 ^[15] utilizando-se uma prensa Zwick 4301 com velocidade de deformação constante 0,5 mm/min. A deformação em cisalhamento foi obtida através de sensores de deformação localizados na região central entre os dois entalhes conforme descrito pela Figura 1.

2.4 Modelo proposto

A arquitetura da rede neural de retropropagação do erro (backpropagation) é mostrada na Figura 4. A rede neural foi configurada para obter a melhor superfície de resposta para as respectivas entradas empregadas. A rede foi alimentada com os valores de deformação específica e tensão os quais representam a curva média dos 8 corpos-de-provas. As unidades de entrada conectam-se a matriz dos pesos, os quais são modificados continuamente através de um processo cíclico que visa obter uma saída otimizada. Utilizou-se uma única camada escondida composta por 64 neurônios, esta configuração foi obtida a partir de uma série de testes com outras configurações possíveis e alterando-se o número de neurônios na camada escondida. Cada neurônio tem um viés associado (o viés tem o efeito de aumentar ou diminuir a entrada da função de ativação da rede, dependendo de seu sinal, positivo ou negativo, respectivamente). A saída é composta de um único vetor representando a tensão de cisalhamento gerada.

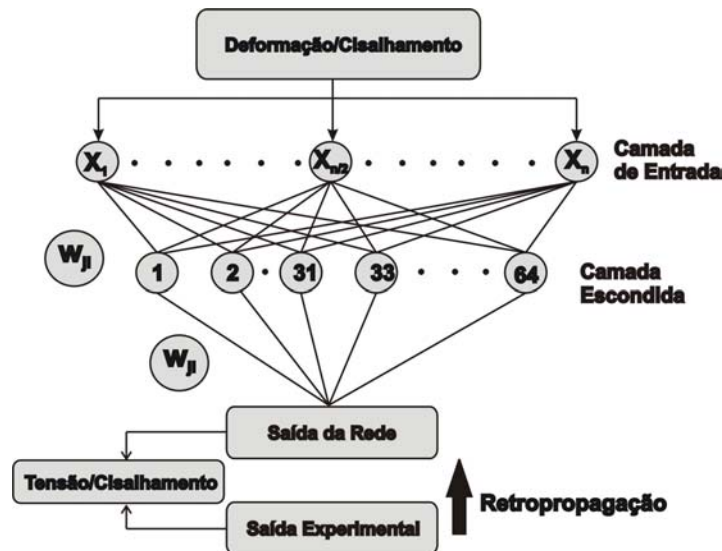


Figura 4 – Arquitetura da rede de retropropagação utilizada.

2.5 Avaliação do desempenho da rede

A base de dados foi dividida em dois conjuntos de forma aleatória, sendo o primeiro conjunto formado por 67% dos dados utilizados para o treinamento da rede e o restante 33% utilizado para simulação. O conjunto de dados utilizados no treinamento foi usado para ajustar as matrizes e seus respectivos pesos em todos os nós até alcançar um nível de erro inferior a 10^{-3} . O desempenho da rede foi avaliado através do cálculo do coeficiente de determinação R^2 que é definido pela equação abaixo:

$$R^2 = 1 - \frac{\sum_{i=1}^M (O(p^{(i)}) - O^{(i)})^2}{\sum_{i=1}^M (O^{(i)} - O)^2} \quad (B)$$

sendo $O(p^{(i)})$ o i -ésimo resultado predito pela rede, $O^{(i)}$ o i -ésimo valor experimental, O a média dos valores experimentais e M o número de dados do conjunto de teste. O coeficiente R^2 representa a capacidade de ajuste da rede. Desta forma, valores altos de R^2 indicam que a rede apresenta elevada capacidade preditiva. Além deste cálculo, comparou-se a rede neural com um processo de regressão polinomial de terceira ordem a fim de verificar-se as respectivas eficiências e justificar a necessidade da utilização de um algoritmo de cálculo robusto, redes neurais perceptron multicamadas, para predição de uma resposta não-linear relativamente simples.

3. RESULTADOS E DISCUSSÃO

Os resultados foram analisados utilizando-se uma rede de retropropagação constituída por três camadas a fim de ajustar a não-linearidade do comportamento do compósito em cisalhamento. Um conjunto formado por sessenta e quatro neurônios totalizou a camada escondida, e o algoritmo de Levenberg-Marquardt ^[11] foi selecionado para aproximar velocidades de treinamento de segunda ordem sem ter de calcular a matriz hessiana ^[16]. A Figura 5 apresenta o gráfico de treinamento da rede, verificando-se que o objetivo do treinamento em lote foi alcançado uma vez que o erro quadrático médio para 99 iterações é inferior ao erro 10^{-3} o qual foi estipulado como meta de treinamento.

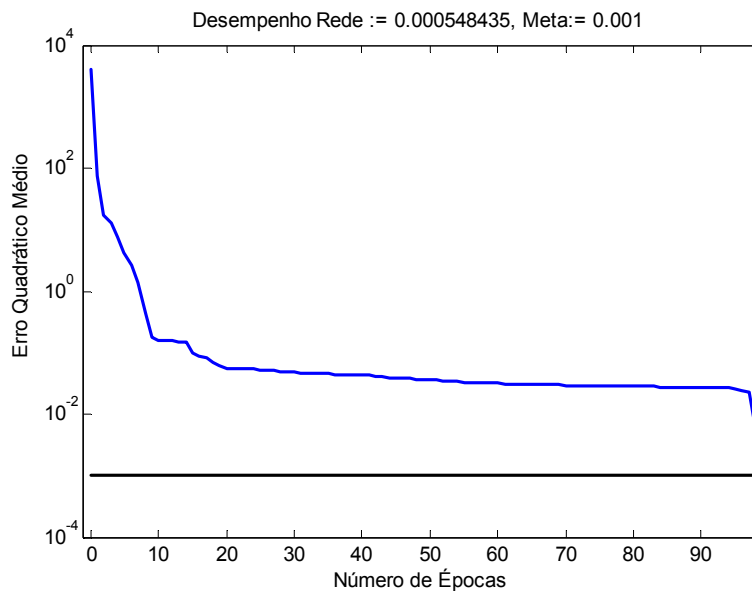


Figura 5 – Evolução do erro quadrático médio em um treino em lote com sucesso

A Figura 6 mostra que as previsões da rede neural ajustaram-se perfeitamente aos dados experimentais apresentado R^2 superior a 0.95 para 71% dos conjuntos testados. Além disso, comparativamente à técnica de regressão polinomial de ordem 3 pode-se constatar uma superioridade em termos de qualidade de predição através do parâmetro R^2 e da leitura atenta da Figura 6.

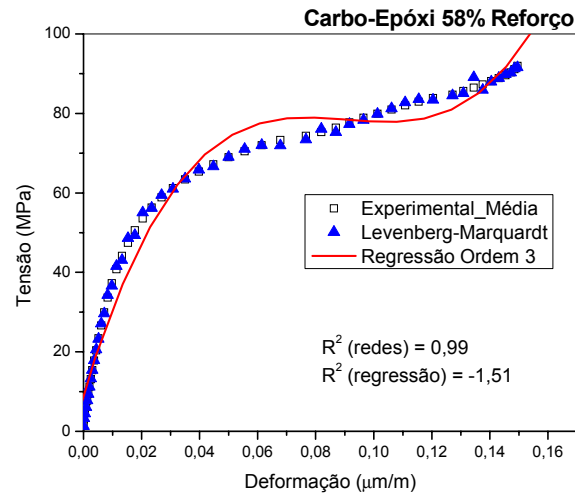


Figura 6 – Gráfico comparativo entre as previsões realizadas utilizando-se regressão polinomial de grau 3 e redes neurais para compósitos epóxi-carbono.

Os resultados mostraram que a aplicação do algoritmo Levenberg-Marquardt conduziu a uma alta qualidade preditiva, uma vez que 71% de R^2 foram encontrados ≥ 0.95 para a configuração de rede adotada, conforme Figura 7. Além disso, verificou-se que este ajustamento preciso é combinado com uma rápida velocidade de convergência. Por outro lado, a aplicação de modelos de regressão polinomial de terceira ordem mostrou-se absolutamente inadequada e o ajustamento das curvas é grosseiro ($R^2 \approx -1.51$).




Figura 7 - Avaliação da porcentagem de desempenho da rede para as diferentes classes de desempenho.

O módulo de cisalhamento foi calculado para os pontos da região linear da

curva gerada pela aplicação do algoritmo Levenberg-Marquardt, obtendo-se o valor de 4.39 ± 0.32 GPa. Desta forma, a aplicação de redes neurais em conjunção com o algoritmo de Levenberg-Marquardt permitiu um ajustamento preciso do conjunto de dados com alta qualidade preditiva.

4 - CONCLUSÕES

O algoritmo de Levenberg-Marquardt (LM) conduziu a uma alta qualidade preditiva, o que pode ser verificado através do cálculo do coeficiente de correlação $R^2 > 0.9$ e aleatorizando-se o conjunto de dados e verificando-se que 71% dos testes apresentaram coeficiente entre 0.95 e 1.00. Além deste fator, a elevada velocidade de processamento dos dados pode ser utilizada na otimização das análises de comportamento mecânico dos compósitos aeronáuticos. A aplicação de análise de regressão polinomial de terceira ordem apresentou um coeficiente de correlação negativo demonstrando que o processo de ajustamento é grosseiro para o caso em questão e uma técnica mais refinada mostrou-se necessária.

5 – AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), projeto nº 150971/2005-2 pelo suporte financeiro. Os autores também gostariam de agradecer à Divisão de Química do IAE/CTA pelo auxílio na execução dos testes mecânicos.

6 – REFERÊNCIAS BIBLIOGRÁFICAS

1. Huber, N.; Tsakmakis, C. A neural network tool for identifying the material parameters of a finite deformation viscoplasticity model with static recovery. ***Computer methods in applied mechanics and engineering***, v.191, p. 353-384, 2001.
2. Zhang, Z.; Friedrich, K. Artificial neural networks applied to polymer composites: a review. ***Composites Science and Technology***, v.63, p. 2029-2044, 2003.
3. Abot, J. L.; Yasmin, A. ; Jacobsen, A.J.; Daniel, I.M. In-plane mechanical, thermal and viscoelastic properties of a satin fabric carbon/epoxy composite. ***Composites Science and Technology***, v.64, p. 263-2684, 2004.
4. Junqing, L.; Hengyi, M.; Yodong, H. A method for characterizes the interface between carbon fiber and epoxy resin: three-parameters exponential pattern. ***Materials Chemistry and Physics***, v.89, p. 367-372, 2005.

5. El Kadi, H.; Al-Assaf, Y. Energy-based fatigue life prediction of fiber/glass composites using modular neural networks. **Composite Structures**, v.57, p. 85-89, 2002.
6. Zhang, Z.; Klein, P.; Friedrich, K. Dynamic mechanical properties of PTFE based short carbon fiber reinforced composites: experiment and artificial neural network prediction. **Composites Science and Technology**, v.62(7-8), p. 1001-1009, 2002.
7. Rai, N.; Pitchumani, R. Neural network-based optimal curing of composite materials. **Journal of Materials Processing & Manufacturing Science**, v. 6, p. 39-62, 1997.
8. El Kadi, H. Modeling the mechanical behavior of fiber-reinforced polymeric composite materials using artificial neural networks – A review. **Composite Structures**, v. xxx, p. xxx, 2005.
9. Jia, J. Davalos, J.F. An artificial neural network for the fatigue study of bonded FRP-wood interfaces. **Composite Structures**, v. xxx, p. xxx, 2005.
10. Haykin, S.S. Neural Networks: a comprehensive foundation, 2nd ed. Prentice Hall, 1998.
11. Marquardt, D.W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v.11, n.2, p. 431-441, 1963.
12. Martínez-Estudillo, A.; Martínez-Estudillo, F.; Hervás-Martínez, C.; García-Pedrajas, N. Evolutionary product unit based neural networks for regresión. **Neural Networks**, v.xx, p. 1-10, 2006.
13. Übeyli, E.D.; Güler, I. Multilayer perceptron neural networks to compute quasistatic parameters of asymmetric coplanar waveguides. **Neurocomputing**, v.62, p. 349-365, 2004.
14. Matlab, **Neural Network Toolbox**, 1994.
15. ASTM D-5379: Test method for shear properties of composite materials by the V-notched beam method, **American Society for Testing and Materials**, 1993.
16. Al-Assaf, Y.; El-Kadi, H. Fatigue life prediction of unidirectional glass fibre/epoxy composite laminae using neural networks. **Composite Structures**, v.53, p. 65-71, 2001.

Artificial Neural Networks Applied to the Modelling the Shear Mechanical Properties to Epoxy Composites Reinforced to Carbon Fibers

ABSTRACT

Inspired by the biological nervous system, artificial neural networks (ANN) have been a powerful tool of Artificial Intelligence for data classification and pattern recognition. Artificial neural networks are being used in medical applications; image recognition and control of dynamic system, but only recently have been used in the prediction of the mechanical behaviour of materials and particularly composites. In this work,

ANNs were considered specifically to predict the shear stress-strain behaviour from carbon fiber/epoxy composites containing 55% by volume of carbon fibers. A multilayered neural network perceptron (MLP) architecture was used, and the results showed that the application of the Levenberg-Marquardt learning algorithm leads to a high predictive quality, i.e. nearly 71% of R^2 were found to be 0.95. The utilization of artificial neural networks lead to the precise adjustment of the shear stress-strain mechanical behaviour comparatively with the analysis of the polynomial regression in result of the non-linear characteristic of these curves.

Keywords: artificial neural networks, regression analysis, composites, carbon fiber.