



APLICAÇÃO DE REDES NEURAI PROFUNDAS NA PREVISÃO DAS TENSÕES DE VON MISES EM ASAS DE ELEVADA RAZÃO DE ASPECTO

Marcos Rogério Tavares Filho, Universidade de São Paulo (USP), marcosrff@usp.br
Marcelo Leite Ribeiro, Universidade de São Paulo (USP), malribei@usp.br

RESUMO EXPANDIDO

INTRODUÇÃO

A busca pela melhoria de projetos aeronáuticos, visando aperfeiçoar características como a redução do arrasto, tem impulsionado a busca por alternativas que auxiliem a alcançar este objetivo, como a utilização de winglets e o aumento da razão de aspecto (RA) das asas. Esta última alternativa proporciona benefícios aerodinâmicos, principalmente na redução do arrasto induzido (CD_i), pois segundo Anderson (2001) a RA é inversamente proporcional ao CD_i , conforme pode ser observado na Equação 1. No entanto, o aumento da RA acarreta maior tensão e momento fletor na raiz da asa Ma et al. (2022). Dessa forma, a avaliação dessas tensões é essencial para garantir a integridade estrutural da aeronave.

$$CD_i = \frac{CL^2}{\pi AR} \quad (1)$$

O Método dos Elementos Finitos (MEF) consolidou-se ao longo das últimas décadas como a principal ferramenta numérica para análise estrutural. No entanto, sua aplicação pode ser computacionalmente custosa, especialmente em problemas que demandam múltiplas análises. Nesse contexto, as Redes Neurais Artificiais (Artificial Neural Networks — ANN) surgem como alternativa promissora, sendo capazes de aprender relações complexas entre variáveis de entrada e saída e, uma vez treinadas, oferecem previsões rápidas em comparação as simulações via MEF, podendo assim auxiliar no desenvolvimento de projetos e na otimização de estruturas Vieira et al. (2024).

Seguindo essa linha, o presente trabalho tem como objetivo apresentar a utilização de uma Rede Neural Profunda (Deep Neural Network — DNN) para a previsão de tensões em uma asa com elevada RA. Esta abordagem visa acelerar o processo de análise estrutural, trazendo benefícios para projetos e para a otimização de estruturas aeronáuticas. Os dados utilizados no treinamento da DNN foram obtidos por meio de simulações no software comercial Abaqus®, devidamente tratados para facilitar o processo de aprendizado.

METODOLOGIA

Os dados de treinamento foram obtidos por simulações no Abaqus®, em que variáveis geométricas da asa (espessuras de nervuras, painéis e longarinas, além das dimensões de flanges e reforços) foram alteradas aleatoriamente com base na teoria de Monte Carlo (MC). Uma macro aplicou essas variações à estrutura de referência e executou múltiplas simulações.

Outra macro extraiu as tensões de von Mises de elementos previamente selecionados. Em seguida, rotinas em Python organizaram os resultados, relacionando-os às dimensões correspondentes para compor o conjunto de dados.

A rede neural adotada pertence à classe perceptron multicamadas (MLP), tendo como entrada as variáveis geométricas e como saída a máxima tensão de von Mises. Diferentes arquiteturas foram exploradas, variando-se o número de camadas ocultas e de perceptrons por camada. As funções de ativação ReLU foram empregadas nas camadas ocultas e a saída foi linear. O treinamento foi realizado com o otimizador Adam, função de perda MSE, batch size de 32 e taxa de aprendizado inicial de 1×10^{-4} , com divisão dos dados em 80% para treino e 20% para validação.

A avaliação considerou as métricas erro quadrático médio (Mean Squared Error – MSE) e erro absoluto médio (Mean Absolute Error – MAE). O MSE é definido por:

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

e penaliza mais fortemente grandes desvios. Já o MAE, dado por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (3)$$

oferece uma medida direta da magnitude média do erro, sendo mais robusto frente a outliers.




RESULTADOS E DISCUSSÃO


Foram realizadas 25 tentativas de treinamento, explorando diferentes arquiteturas e taxas de aprendizado. Inicialmente, testaram-se redes com sete e dez camadas, variando o número de perceptrons em cada camada. No entanto, os resultados não foram satisfatórios, sendo que no caso das dez camadas observou-se indício de overfitting, com redução da capacidade de generalização.

A melhoria significativa ocorreu na 25ª tentativa, em que foi utilizada uma arquitetura com sete camadas de 1000, 900, 800, 700, 600, 500 e 400 perceptrons, combinada com taxa de aprendizado de 2×10^{-3} . Nessa configuração, todos os erros percentuais ficaram abaixo de 5% em relação às simulações no Abaqus, com erro máximo de aproximadamente 3,75% e mínimo próximo de 0,4%.

A Figura 1 ilustra os resultados obtidos: a subfigura (a) mostra a correlação entre os valores previstos pela rede e os obtidos no Abaqus, enquanto a subfigura (b) apresenta os erros percentuais individuais, confirmando a consistência do modelo na previsão das tensões de von Mises.



(a)



(b)

Figura 1. (a) Comparação entre os valores de tensão máxima obtidos no Abaqus e previstos pela rede neural; (b) Erro percentual por simulação.

CONCLUSÃO

Este trabalho demonstrou o potencial das DNNs como alternativa ao MEF para a previsão de tensões em asas de elevada razão de aspecto. Embora diversas arquiteturas tenham sido testadas sem sucesso inicial, a configuração com sete camadas e taxa de aprendizado de 2×10^{-3} apresentou desempenho satisfatório, com erros percentuais inferiores a 5% em relação aos dados de referência.

Os resultados indicam que a utilização de DNN pode reduzir significativamente o custo computacional de análises estruturais, possibilitando aplicações em fases preliminares de projeto e em processos de otimização. Trabalhos futuros podem explorar estratégias de regularização para mitigar overfitting, bem como a ampliação do banco de dados de treinamento para maior generalização.

REFERÊNCIAS

- Anderson, J. D. (2001). *Fundamentals of Aerodynamics*. McGraw-Hill, New York, 3rd edition.
- Ma, Y., Karpuk, S., and Elham, A. (2022). Conceptual design and comparative study of strut-braced wing and twin-fuselage aircraft configurations with ultra-high aspect ratio wings. *Aerospace Science and Technology*, 121.
- Vieira, A. F. C., Filho, M. R. T., Eguea, J. P., and Ribeiro, M. L. (2024). Optimization of structures and composite materials: A brief review. *Eng*, 5(4):3192–3211.

AGRADECIMENTOS

Expressamos nossa sincera gratidão a todos que colaboraram para a realização deste projeto, em especial a Matheus Urzedo Quirino, Mateus Carpena Neto, José Fernando Cárdenas Barbosa e João Victor Barreto Netto, pelo valioso apoio e orientação. Agradecemos também aos amigos e familiares pelo incentivo e auxílio. Este trabalho só se tornou possível graças à contribuição de cada um de vocês.

RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.