IDENTIFICAÇÃO DA DINÂMICA LONGITUDINAL DO CESSNA 177B EM SUBESCALA VIA REDES NEURAIS FEEDFORWARD (FFNN)

Aline Gabrielle de Souza, Clécio Fischer.

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP), Câmpus São José dos Campos, Rod. Pres. Dutra, km 145 - s/n - Jardim Diamante, 12223-201 - São José dos Campos-SP, Brasil, a.gabrielle@aluno.ifsp.edu.br, clecio@ifsp.edu.br.

Resumo

O presente trabalho aborda a estimação dos coeficientes aerodinâmicos longitudinais (coeficiente de sustentação *CL*, coeficiente de arrasto *CD* e coeficiente de momento de arfagem *Cm*) de uma aeronave Cessna 177B Cardinal em subescala (escala de 22,2%), utilizando uma arquitetura de Rede Neural *Feedforward* (FFNN). A abordagem baseia-se exclusivamente no aprendizado supervisionado a partir de dados experimentais de ensaios em voo livre instrumentados a 100 Hz, sem a imposição prévia de equações diferenciais da dinâmica de voo. A rede neural foi estruturada com 8 neurônios na camada oculta e funções de ativação tangente hiperbólica, sendo treinada com dados de uma manobra de perturbação no profundor e validada com uma segunda manobra, independente da primeira. Os resultados demonstraram a capacidade do estimador não linear, alcançando coeficientes de determinação (R^2) de 0,8053 para sustentação (*CL*) e 0,7059 para momento (*Cm*) em dados de validação inéditos, demonstrando a robustez do estimador frente a dados ruidosos de voo. O modelo FFNN comprovou ser um estimador viável para a reconstrução dos coeficientes aerodinâmicos em tempo real, viabilizando sua aplicação em aeronaves remotamente pilotadas e no desenvolvimento de sistemas avançados de controle de voo.

Palavras-chave: Identificação de Sistemas. Redes Neurais *Feedforward*. Cessna 177B. Coeficientes Aerodinâmicos. Ensaios em Voo.

Área do Conhecimento: Engenharia Aeronáutica / Inteligência Artificial Aplicada

Introdução

A identificação precisa de modelos dinâmicos de aeronaves desempenha um papel fundamental na engenharia aeronáutica moderna, sendo indispensável para o projeto de sistemas de controle de voo, simulação de desempenho e avaliação de estabilidade. Tradicionalmente, a estimativa de parâmetros aerodinâmicos baseia-se em métodos clássicos de identificação no domínio do tempo, como o Output Error Method (OEM), que exigem a formulação prévia de equações diferenciais baseadas nos princípios da mecânica do voo (Jategaonkar, 2015; Stevens; Lewis, 2015). Embora consolidados, esses métodos dependem de hipóteses de linearização e do conhecimento a priori da estrutura do modelo físico.

Com o avanço da computação e das técnicas de aprendizado de máquina, abordagens baseadas em redes neurais artificiais emergem como alternativas promissoras do tipo 'caixa-preta' ou 'baseadas puramente em dados' (Linse, 1991). As Redes Neurais *Feedforward* (FFNN) possuem a propriedade de aproximadores universais de funções, permitindo capturar relações altamente não lineares e complexas entre as variáveis de entrada de voo (como ângulo de ataque, deflexão de superfícies de comando e taxas angulares) e as forças e momentos aerodinâmicos resultantes, sem a necessidade de predefinir a forma das equações físicas.

O presente trabalho tem como objetivo desenvolver, treinar e validar um modelo de estimador aerodinâmico baseado em uma Rede Neural *Feedforward* (FFNN) para a reconstrução temporal dos coeficientes aerodinâmicos longitudinais — coeficiente de sustentação (*CL*), coeficiente de arrasto (*CD*) e coeficiente de momento de arfagem (*Cm*) — de uma aeronave Cessna 177B Cardinal em subescala (22,2% do tamanho real). A avaliação foca estritamente na capacidade da rede neural em atuar como um estimador não linear preciso a partir de dados de ensaios em voo reais, analisando sua precisão temporal e capacidade de generalização.

Metodologia

A base de dados utilizada neste estudo provém de ensaios em voo livre de uma aeronave Cessna 177B Cardinal em subescala, a mesma plataforma experimental empregada por Nepomuceno (2022) em estimativas aerodinâmicas longitudinais não lineares, construída respeitando a similaridade dinâmica pelo Número de Froude (Wolowicz; Yancey; Jatoft, 1979), o que garante a representatividade dos fenômenos aerodinâmicos da aeronave em escala real. Os sensores a bordo registraram as variáveis de estado e de comando a uma taxa de amostragem de 100 Hz. Para o desenvolvimento e validação do estimador neural, foram empregados dois conjuntos de dados independentes, cada um correspondente a uma manobra distinta de perturbação no profundor (*doublet*): um conjunto de dados, referente à manobra utilizada para o treinamento da rede neural, e um segundo conjunto, referente a uma manobra independente da primeira, empregado exclusivamente para a validação cruzada do modelo. O perfil temporal dessas manobras — isto é, a deflexão aplicada ao profundor e a correspondente resposta em ângulo de ataque — pode ser observado nas duas séries inferiores das Figuras 1 e 2, apresentadas na seção Resultados.

A arquitetura adotada consistiu em uma Rede Neural *Feedforward* (FFNN) de duas camadas (uma camada oculta e uma camada de saída). O vetor de entradas da rede neural foi composto pelas variáveis de estado e controle instantâneas pertinentes à dinâmica longitudinal: velocidade adimensionalizada ou componentes de velocidade, ângulo de ataque (α), taxa de arfagem (q), ângulo de arfagem (θ) e deflexão do profundor (δe). O vetor de saídas estimadas é dado pelos coeficientes aerodinâmicos longitudinais adimensionais: *CL*, *CD* e *Cm*.

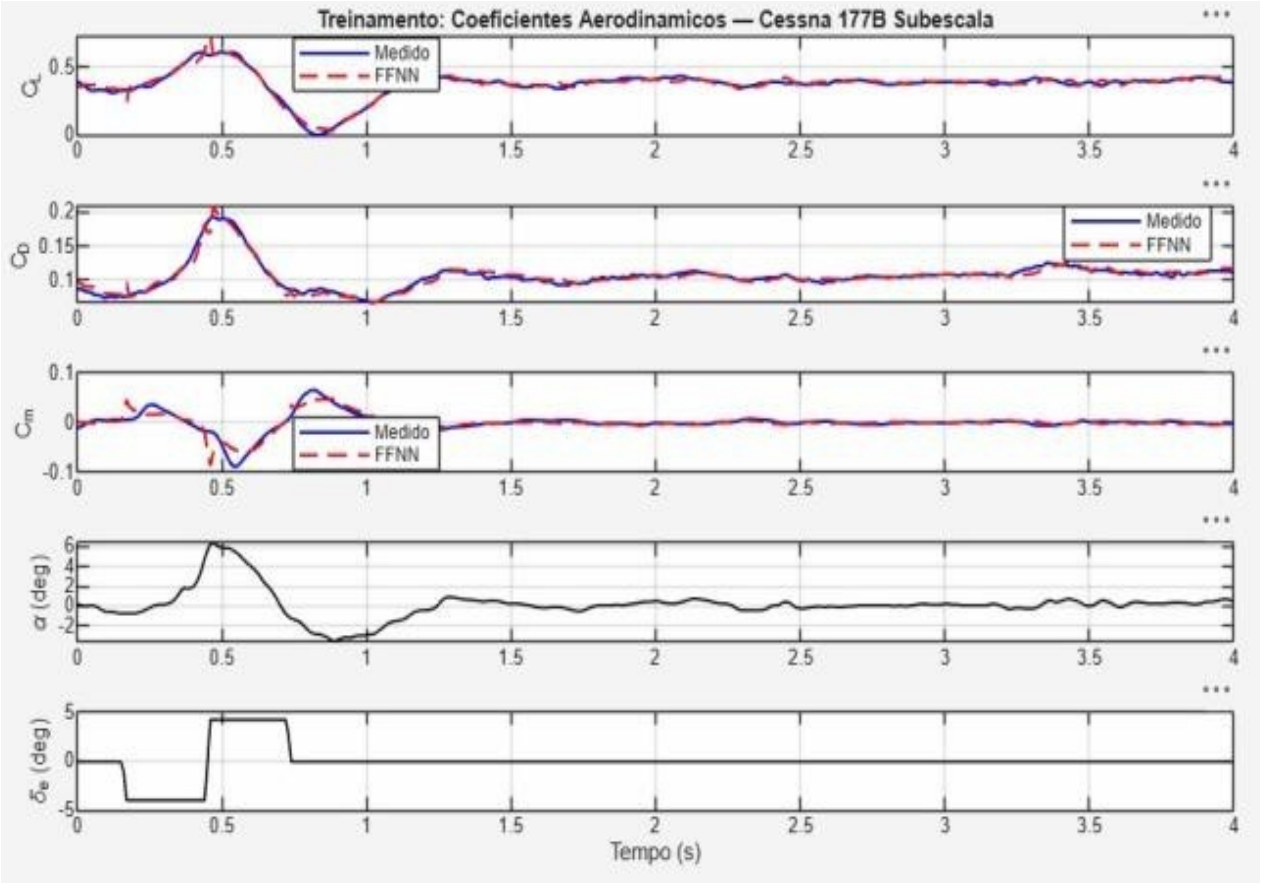
Após testes de sensibilidade estrutural, definiu-se a topologia da rede com 8 neurônios na camada oculta. As funções de ativação adotadas para a camada oculta e de saída foram do tipo tangente hiperbólica sigmoide, ajustadas por parâmetros de ganho ($\gamma 1 = 0{,}50$ e $\gamma 2 = 0{,}50$). Os dados de entrada e saída foram devidamente normalizados para o intervalo [-0,5, 0,5] para otimizar a convergência do algoritmo de treinamento. O ajuste dos pesos conexionais foi realizado minimizando a função custo do erro quadrático médio entre os coeficientes aerodinâmicos observados nos voos e as saídas preditas pela rede, ao longo de 500 iterações de otimização utilizando o algoritmo de Retropropagação com Ganho de Kalman, configurado com uma taxa de aprendizado (μ) de 0,125.

Resultados

A avaliação do desempenho da FFNN como estimador dos coeficientes aerodinâmicos longitudinais foi conduzida comparando as séries temporais preditas pela rede com os dados de voo medidos, tanto no conjunto de treinamento quanto no conjunto de validação, composto por uma manobra inédita e independente da manobra de treinamento.

Figura 1 – Coeficientes aerodinâmicos medidos e estimados pela FFNN durante o treinamento com a manobra de perturbação no profundor. De cima para baixo: *CL*, *CD*, *Cm*, ângulo de ataque (*α*) e deflexão do profundor (*δe*) — as duas últimas séries evidenciam o perfil temporal da manobra tipo *doublet* aplicada.

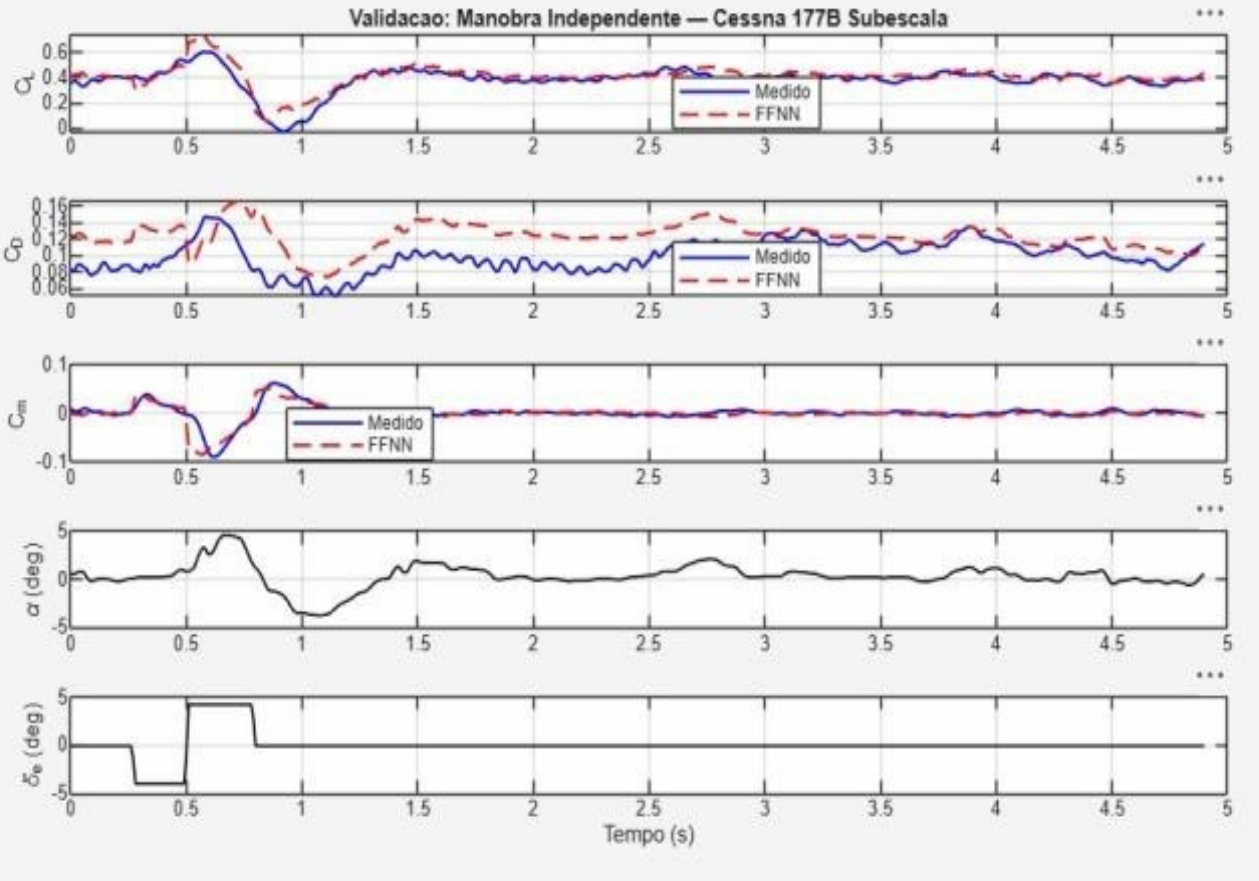
Fonte: elaborado pelo próprio autor.



A Figura 1 evidencia a boa aderência entre os coeficientes medidos e estimados ao longo de toda a manobra de treinamento, incluindo o trecho transiente induzido pela deflexão do profundor.

Figura 2 – Coeficientes aerodinâmicos medidos e estimados pela FFNN na etapa de validação cruzada, obtida a partir de uma segunda manobra de perturbação no profundor, independente da manobra de treinamento.

Fonte: elaborado pelo próprio autor.



A Figura 2 mostra que a rede manteve boa aderência para os coeficientes de sustentação (*CL*) e momento de arfagem (*Cm*) mesmo diante de uma manobra inédita, ao passo que o coeficiente de arrasto (*CD*) apresentou maior dispersão em relação aos dados medidos. A Tabela 1 sintetiza as métricas quantitativas de desempenho obtidas para os coeficientes *CL*, *CD* e *Cm* no conjunto de validação, incluindo o Erro Médio Quadrático (RMSE) e o Coeficiente de Determinação (R^2).

Tabela 1 – Desempenho do estimador FFNN na predição dos coeficientes aerodinâmicos (validação com manobra de profundor independente).

Coeficiente Aerodinâmico	RMSE	Coeficiente de Determinação (R^2)
Sustentação (*CL*)	0,049775	0,8053
Momento de Arfagem (*Cm*)	0,010152	0,7059
Arrasto (*CD*)	0,029469	0,2499

Fonte: elaborado pelo próprio autor.

Observa-se pela Tabela 1 que a rede neural alcançou resultados robustos na estimação dos coeficientes aerodinâmicos durante a fase de validação com dados inéditos. O coeficiente de sustentação (*CL*) apresentou um coeficiente de determinação R^2 = 0,8053, demonstrando que a FFNN capturou com fidelidade a dinâmica induzida pelas variações no ângulo de ataque e deflexão de profundor. O momento de arfagem (*Cm*) também obteve aderência sólida, com R^2 = 0,7059, validando o aprendizado da rede sobre as oscilações longitudinais da aeronave. Já o coeficiente de arrasto (*CD*) apresentou um ajuste inferior (R^2 = 0,2499), o que é fisicamente justificado pela natureza da manobra executada: manobras do tipo *doublet* de profundor excitam primariamente transientes de arfagem com variações diminutas na velocidade verdadeira (Vt), dificultando o isolamento do arrasto em relação ao ruído dos sensores.

A qualidade preditiva é reforçada pelo Critério de Theil (U = 0,0607) para a sustentação, indicando uma predição altamente fiel à realidade, dado que valores de U abaixo de 0,3 são considerados ótimos na literatura aeronáutica (Jategaonkar, 2015). A análise temporal dos resíduos revelou distribuição aleatória com média próxima a zero ao longo da manobra de validação, confirmando a estabilidade numérica do estimador. A convergência da função custo ocorreu de forma suave ao longo das 500 iterações de treinamento, sem indícios de *overfitting*, garantindo a capacidade de generalização do modelo neural para diferentes condições de voo do Cessna 177B em subescala.

Discussão

Os resultados obtidos confirmam a eficácia das Redes Neurais *Feedforward* como estimadores diretos de forças e momentos aerodinâmicos a partir de dados de voo reais (Linse, 1991). A capacidade da FFNN de mapear os coeficientes de sustentação e momento com precisão de R^2 entre 0,70 e 0,80 valida a hipótese de que modelos baseados em dados conseguem capturar a essência da dinâmica de voo sem a necessidade de modelagem analítica prévia, corroborando os resultados obtidos por Nepomuceno (2022) na mesma plataforma subescala.

A elevada concordância verificada na etapa de validação cruzada demonstra que o processo de regularização e a escolha da topologia com 8 neurônios proporcionaram uma generalização adequada para a rede neural. Esse aspecto é particularmente relevante para aplicações em tempo real, onde o estimador neural pode ser embarcado no sistema de aviônica para fornecer estimativas instantâneas de carga e coeficientes aerodinâmicos, auxiliando algoritmos de controle adaptativo e identificação de envelopes de voo em tempo real.

Conclusão

O estudo demonstrou com sucesso a viabilidade e a precisão da aplicação de Redes Neurais *Feedforward* (FFNN) na estimação dos coeficientes aerodinâmicos longitudinais (*CL*, *CD* e *Cm*) de uma aeronave subescala Cessna 177B Cardinal. A arquitetura desenvolvida com 8 neurônios na camada oculta apresentou excelente capacidade de ajuste temporal e generalização, alcançando R^2 superior a 0,80 para sustentação e 0,70 para momento em dados inéditos de validação.

Conclui-se que a abordagem por rede neural se mostra uma ferramenta robusta e eficiente para a reconstrução não linear de forças e momentos aerodinâmicos em tempo real. Para contornar a limitação na estimação do arrasto (*CD*), trabalhos futuros devem incorporar manobras que excitem significativamente o estado de velocidade da aeronave, tais como trajetórias de aproximação e arremetida, fujoides ou variações rápidas de tração (*thrust sweeps*). Em trabalhos futuros, pretende-se estender a aplicação da metodologia para a dinâmica lateral-direcional e explorar a extração analítica de derivadas de estabilidade e controle a partir do mapeamento neural obtido.

Referências

JATEGAONKAR, R. V. Flight Vehicle System Identification: A Time-Domain Methodology. Reston: American Institute of Aeronautics and Astronautics (AIAA), 2015.

LINSE, D. J. Neural Networks for Aircraft System Identification. Hampton: NASA Langley Research Center, 1991.

NEPOMUCENO, L. M. Application of Subscale Flight Testing for Nonlinear Longitudinal Aerodynamic Estimates. 2022. Tese (Doutorado em Engenharia Aeronáutica e Mecânica) – Instituto Tecnológico de Aeronáutica, São José dos Campos, 2022.

STEVENS, B. L.; LEWIS, F. L. Aircraft Control and Simulation: Dynamics, Controls Design, and Autonomous Systems. 3. ed. Hoboken: John Wiley & Sons, 2015.

WOLOWICZ, C. H.; YANCEY, R. B.; JATOFT, R. L. Similitude Requirements and Scaling Relationships for Aircraft Development. Edwards: NASA Dryden Flight Research Center, 1979.

Agradecimentos

O presente trabalho foi realizado com o apoio do Instituto Federal de São Paulo (IFSP - Câmpus São José dos Campos) no âmbito do Programa de Iniciação Científica e Tecnológica.