

**REDES NEURAIIS ARTIFICIAIS RECORRENTES NA IDENTIFICAÇÃO
DE RESPOSTAS DE DIFERENTES MANOBRAS DE UMA AERONAVE
REGIONAL**

**RECURRENT ARTIFICIAL NEURAL NETWORKS FOR
IDENTIFICATION OF RESPONSES TO DIFFERENT MANEUVERS OF A
REGIONAL AIRCRAFT**

**REDES NEURONALES ARTIFICIALES RECURRENTES EN LA
IDENTIFICACIÓN DE RESPUESTAS DE DIFERENTES MOVIMIENTOS DE
UNA AERONAVE REGIONAL**

LUCIANE DE FÁTIMA RODRIGUES DE SOUZA¹

EDUARDO MORGADO BELO²

FLÁVIO DONIZETI MARQUES³

¹ Professora do Departamento de Matemática – FIRA – Faculdades Integradas Regionais de Avaré – Avaré/SP e da Faculdade de Tecnologia de Botucatu. Licenciada em Matemática. Mestre e Doutora em Engenharia Mecânica pela USP-São Carlos. E-mail: luciane_fa@yahoo.com.br.

² Professor Titular do Departamento de Engenharia de Materiais Aeronáutica e Automobilística da Escola de Engenharia de São Carlos – USP – São Carlos/SP. E-mail: belo@sc.usp.br.

³ Professor Livre Docente do Departamento de Engenharia de Materiais Aeronáutica e Automobilística. da Escola de Engenharia de São Carlos – USP – São Carlos/SP. E-mail: fmarques@sc.usp.br.

REDES NEURAS ARTIFICIAIS RECORRENTES NA IDENTIFICAÇÃO DE RESPOSTAS DE DIFERENTES MANOBRAS DE UMA AERONAVE REGIONAL

RESUMO

Devido ao fato de uma aeronave poder se movimentar em qualquer direção no espaço, a representação de seus movimentos muitas vezes se torna um trabalho bastante complexo, pois envolve um conjunto de equações de movimento acopladas entre si. Ainda, simulações de efeitos não lineares em aeronaves usando métodos tradicionais podem ser caras computacionalmente e de difícil implementação; além disso, a validade e a utilidade dos modelos matemáticos dependem do grau de precisão com que foram modelados às forças e aos momentos que agem sobre o veículo em voo. Neste contexto, o objetivo deste trabalho é identificar o modelo dinâmico de uma aeronave regional usando redes neurais artificiais recorrentes. São conhecidas respostas de 6 manobras diferentes da aeronave realizadas em voo e para identificar as velocidades angulares em cada uma delas, serão usados, como entradas para a rede neural, os sinais de entrada dos profundores, do leme e dos ailerons. Para treinar a rede neural, serão usadas tanto as respostas da manobra de *dutch roll*, que é uma oscilação amortecida em guinada acoplada com rolamento e pode ser bastante desconfortável para piloto e tripulação quando ocorre por um longo período, como as respostas de curto período. Depois de treinada, a rede neural obtida será usada para simular a realização das outras manobras. Também, visando a uma análise de estabilidade dos modos da aeronave, serão traçados os planos de fase de θ contra $\dot{\theta}$, de ϕ contra $\dot{\phi}$ e de ψ e $\dot{\psi}$.

PALAVRAS-CHAVE: Ensaio em voo. Identificação. Redes Neurais Artificiais.

RECURRENT ARTIFICIAL NEURAL NETWORKS FOR IDENTIFICATION OF RESPONSES TO DIFFERENT MANEUVERS OF A REGIONAL AIRCRAFT

ABSTRACT

Due to the fact that an aircraft can move in any direction in space, the representation of their movements often becomes a very complex work, because it involves a set of equations of motion coupled with each other. Still, simulations of non-linear effects on aircraft using traditional methods can be computationally expensive and difficult to implement and also the validity and usefulness of mathematical models depend on the degree of accuracy with which the forces and the moments that act on the vehicle in flight were modeled. In this context, the objective of this study is to identify the dynamic model of a regional aircraft using recurrent artificial neural networks. 6 responses due to different maneuvers of the aircraft in flight are known and in order to identify each angular velocity, the elevator, the rudder and the ailerons signals will be used as inputs for the neural network. To train the neural network, the responses of the short period and of the dutch roll manoeuvres will be used, being the latter a damped oscillation coupled in yaw with roll which usually is quite uncomfortable for the pilot and crew when it occurs over a long period. After trained, the neural network obtained will be used to simulate other maneuvers. Also, seeking a stability analysis of the aircraft oscillation modes, the phase plans of θ versus $\dot{\theta}$, ϕ versus $\dot{\phi}$ and ψ versus $\dot{\psi}$ will be plotted.

KEYWORDS: Artificial Neural Networks. Flight tests. Identification.

REDES NEURONALES ARTIFICIALES RECURRENTE EN LA IDENTIFICACIÓN DE RESPUESTAS DE DIFERENTES MOVIMIENTOS DE UNA AERONAVE REGIONAL

RESUMEN

Debido a que las aeronaves pueden moverse en cualquier dirección en el espacio, la representación de sus movimientos a menudo se convierte en un trabajo muy complejo porque se trata de un conjunto de ecuaciones del movimiento, junto con los demás. Sin embargo, las simulaciones de los efectos no lineales en los aviones que utilizan métodos tradicionales pueden ser computacionalmente costoso y difícil de aplicar y también la validez y utilidad de los modelos matemáticos depende de la precisión con la que se modelaron las fuerzas y momentos que actúan en el vehículo de vuelo. En este contexto, el objetivo de este estudio es identificar el modelo dinámico de un avión regional mediante redes neuronales artificiales solicitantes. Son conocidas las respuestas de 6 diferentes maniobras de las aeronaves en vuelo y llevó a cabo para determinar las velocidades angulares en cada una, se utilizan como insumos para las señales de entrada de red neuronal de los elevadores, timón y alerones. Para entrenar la red neuronal se utilizarán las respuestas de maniobra *dutch roll*, que es una oscilación amortiguada, a su vez junto con la superficie y puede ser muy incómodo para el piloto y la tripulación cuando se produce durante un largo período y también la respuesta de corto plazo. Una vez capacitados, la red neuronal se utiliza para identificar las respuestas de la realización de otras maniobras. Además, para el análisis de la estabilidad de los modos de la aeronave, se destacó los planes para la etapa de θ contra $\dot{\theta}$, de ϕ contra $\dot{\phi}$ y de ψ e $\dot{\psi}$.

PALABRAS CLAVE: Identificación. Prueba de vuelo. Redes neuronales artificiales.

1 INTRODUÇÃO

A dinâmica de voo é a área da engenharia aeronáutica que estuda o movimento de veículos voando pela atmosfera. A natureza complexa da atmosfera, o comportamento dinâmico de uma aeronave, o uso de materiais compósitos causando uma redução de peso são alguns dos fatores que garantem a esta área problemas desafiadores. Por exemplo, o piloto, para garantir a segurança da estrutura e consequentemente da tripulação, deve conhecer os limites do projeto da aeronave.

O advento dos computadores e dos sistemas digitais de aquisição de dados para instrumentação revolucionou as técnicas de identificação de parâmetros aplicadas a ensaios em voo, pois tornou possível transferir de modo automático, grandes quantidades de dados da instrumentação para o processamento de computadores, possibilitando técnicas de identificação mais complexas. A identificação de sistemas tem grande aplicabilidade na indústria aeronáutica, pois pode ajudar no desenvolvimento de técnicas de controle como piloto automático, simuladores bastante precisos e sistemas *Flight-By-Wire*. As Redes Neurais Artificiais têm se mostrado ferramentas poderosas,

permitindo a modelagem dos processos através de identificação, utilizando-se dos dados de entrada e saída dos mesmos. Pesquisas em identificação de manobras estão ganhando considerável número de pesquisadores devido aos benefícios que podem trazer aos pilotos que operam aeronaves militares e caças modernos.

Brian (2000) mostrou um problema que envolve predição e identificação de trajetórias contínuas em aeronaves de combate em que são conhecidas apenas informações parciais destas. O problema foi resolvido usando uma rede neural dinâmica que usou como dados de entrada os estados do sistema dinâmico e, através da obtenção das relações entre acelerações e velocidades, possibilitou que todos os modos fossem identificados.

Souza et al. (2005) mostraram o desenvolvimento e implementação de um simulador de dinâmica de aeronaves, criado objetivando obtenção de respostas de velocidades escalares e angulares para serem usadas como entrada para uma rede neural artificial e então identificar o modelo. O modelo matemático não linear apresentado por Etkin e Reid (1996) foi usado, pois apesar deste modelo possuir simplificações, apresenta resultados bastante coerentes. O software

desenvolvido foi aplicado na simulação da aeronave de combate A4-D em diversas condições de voo. Uma rede neural artificial recorrente foi treinada usando dados de 3 condições de voo distintas em um envelope de voo e, depois de verificado o treinamento, esta foi usada para estimar as respostas em outros 4 pontos distintos deste envelope. O trabalho apresentou resultados bastante satisfatórios.

Neste contexto, o objetivo deste trabalho é identificar as respostas de uma aeronave regional usando os dados colhidos em testes realizados em voo usando redes neurais artificiais que têm apresentado resultados bastante satisfatórios em problemas deste nível.

Especificamente, serão identificadas as velocidades angulares de rolamento p , de arfagem q e velocidade angular de guinada r usando entradas de aileron, leme e profundor de dados referentes a 6 condições de voo diferentes da aeronave, visando futuramente usar estes resultados para modelar trajetórias de aeronaves. Todas as manobras foram realizadas com o Flap 0 e trem de pouso recolhido. Para treinar a rede neural, serão usados os dados das manobras de *dutch roll* e de curto período da aeronave. A seguir, visando a uma análise de estabilidade, foram traçados os planos de fases dos ângulos contra

suas derivadas, ou seja, velocidades angulares (θ e $\dot{\theta}$, ϕ e $\dot{\phi}$ e ψ e $\dot{\psi}$).

NOMENCLATURAS

$u(k)$ = vetor de entrada

$y(k)$ = vetor de saída

p = velocidade de rolamento, (graus/s)

q = velocidade de arfagem, (graus/s)

r = velocidade de guinada, (graus/s)

V – Velocidade do ar (Km/h)

Símbolos gregos

β = ângulo de guinada, graus

θ = ângulo de arfagem, graus

α = ângulo de ataque, graus

ψ = ângulo de rolamento, graus

δ_e = deflexão dos profundores, graus

δ_r = deflexão do leme, graus

δ_a = deflexão dos ailerons, graus

Subscritos

a relativo ao aileron

e relativo ao profundor

r relativo ao leme

2 REDES NEURAS ARTIFICIAIS

Redes neurais artificiais são sistemas de processamento de informações com a capacidade de aprender através de exemplos (Haykin, 1994). Baseado em conceitos derivados da neurobiologia, são compostas por um conjunto de

unidades de processamento interconectadas, chamados neurônios. Os neurônios processam os sinais apresentados à rede neural, acumulando cada estímulo e transformando o valor total usando uma função, ou seja, a função de ativação.

Os estímulos de um neurônio são modificados pelo valor real chamado peso sináptico, o que caracteriza a respectiva ligação entre os neurônios. A Figura 1 mostra uma representação típica de um neurônio j , onde x_1, x_2, \dots, x_p são sinais de estímulo, $w_{j1}, w_{j2}, \dots, w_{jp}$ são pesos sinápticos, θ_j é um “bias”, v_j é o potencial de ativação, o_j é o neurônio de saída e $\varphi(\cdot)$ é a função de ativação (geralmente adotada não linear).




Figura 1. Representação típica de um neurônio.

Então, da Figura 1, pode-se observar que a saída do neurônio é dada por:

$$o_j = \varphi \left(\theta_j + \sum_{i=1}^p w_{ji} x_i \right) \quad (1)$$

Arquitetura de rede é o nome dado a forma de arranjo de neurônios em camadas e como eles estão conectados. Redes neurais típicas têm a seguinte arquitetura: (1) camada de entrada - onde o estímulo de entrada é apresentado à rede; (2) camadas ocultas - camadas internas de uma rede, e (3)

camada de saída - a última camada da rede, onde as saídas são dadas. Essa arquitetura de rede típica é comumente referida como multicamadas

Uma vez treinada, pode-se supor que a rede armazenou os conhecimentos que lhe foram fornecidos. No entanto, o conhecimento em uma rede neural não é armazenado em uma localização específica, dependendo então de sua topologia e da magnitude dos pesos na camada de entrada.

A generalização de uma rede neural artificial é a capacidade de reproduzir sinais desejados para sinais de entrada diferentes dos que foram utilizados durante o treinamento da rede, ou seja, é a capacidade de capturar a dinâmica do sistema a ser emulado (Saravanan e Dyear, 1994).

2.1 Treinamento de uma rede neural

Para atingir um conjunto desejável de pesos sinápticos de uma arquitetura pré-definida de rede, um processo de treinamento é necessário. O treinamento é geralmente baseado em um sistema de otimização para ajustar os parâmetros de rede (principalmente, os pesos) em relação a um conjunto de entrada-saída a ser emulado pelo modelo de rede neural (sistema de aprendizado supervisionado).

O algoritmo *backpropagation* é baseado em uma técnica de gradiente descendente (Haykin, 1994). Tem sido amplamente aplicado em treinamento de redes neurais. Um regime de treinamento mais eficiente pode ser obtido utilizando a técnica de otimização de Levenberg-Marquardt (LMA).

2.1.1 Algoritmo de Levenberg-Marquardt (LMA)

Este algoritmo é uma variação do método de Newton para minimizar funções que são somas de quadrados de outras funções não lineares (Hagan *et al.*, 1996). O LMA fornece um melhor desempenho quando comparado com o algoritmo *backpropagation* típico.

Do método de Newton a regra de adaptação dos pesos é:

$$\mathbf{w}_{n+1} = \mathbf{w}_n - \mathbf{H}_n^{-1} \mathbf{g}_n, \quad (2)$$

onde, \mathbf{w} é a matriz de pesos, n é um passo da iteração, \mathbf{H} é a matriz Hessiana e \mathbf{g} a matriz gradiente.

Para o índice de desempenho como uma soma de funções de quadráticas, a matriz Hessiana pode ser aproximada em termos da matriz Jacobiana \mathbf{J} , a qual contém as derivadas primeiras dos erros da rede neural em relação aos pesos e bias. Então,

$$\mathbf{H} \cong \mathbf{J}^T \mathbf{J}. \quad (3)$$

Quando a aproximação usada na Equação (3) é substituída na Equação (2), o método de Gauss-Newton é obtido, isto é:

$$\mathbf{w}_{n+1} = \mathbf{w}_n - [\mathbf{J}_n^T \mathbf{J}_n]^{-1} \mathbf{g}_n. \quad (4)$$

Um problema que pode surgir no método de Gauss-Newton é que a matriz $[\mathbf{J}^T \mathbf{J}]$ pode não ter inversa. Isto pode ser resolvido assumindo a uma modificação da matriz $[\mathbf{J}^T \mathbf{J}]$ que leva ao LMA:

$$\mathbf{w}_{n+1} = \mathbf{w}_n - [\mathbf{J}_n^T \mathbf{J}_n + \mu_n \mathbf{I}]^{-1} \mathbf{g}_n, \quad (5)$$

onde, \mathbf{I} é a matriz identidade e μ é um escalar.

O escalar μ apresenta um importante parâmetro do LMA. Quando μ_n é nulo, a adaptação de pesos é feita basicamente pelo método Gauss-Newton. Já, quando μ_n é suficientemente grande, a Equação (5) torna-se o método do gradiente descendente com pequeno passo. Escolhendo um valor adequado de μ , o LMA provê resultado bastante eficiente de minimização de erro.

3 IDENTIFICAÇÃO DO MODELO DINÂMICO DA AERONAVE

3.1 Dados das manobras de voo da aeronave

Dados de ensaio em voo de uma aeronave regional serão usados para identificação de seu comportamento dinâmico. Precisamente, são conhecidas respostas de 6 manobras distintas

realizadas por esta, estando em todas com o trem de pouso recolhido e usando Flap 0.

A Tabela 1 a mostra dados de peso, posição do CG e temperatura referentes a cada conjunto de dados medidos em voo e usados para análise.

Tabela 1. Dados das manobras

Manobras	Peso da aeronave	Posição do CG	Temperatura ISA (+ graus)
<i>Longitudinal Trim</i>	26990 kgf	18.5%	+9.7
<i>Short Period</i>	27120 kgf	18.5%	+9.7
<i>Level Flight Speed</i>	31670 kgf	20.8 %	+ 13.5
<i>Sweep</i>			
<i>Dutch Roll</i>	32860 kgf	17.5%	+ 0.2
<i>Steady Heading Sideslip</i>	31520 kgf	8.9%	+ 12.5
<i>Roll Response</i>	35990 kgf	7.6%	+ 12.7

Das manobras realizadas durante os ensaios, o *dutch roll* é a mais complexa, pois é uma oscilação caracterizada por uma combinação de rolamento, guinada e escorregamento lateral, sendo que o contínuo não é confortável para ambos, piloto e tripulação. No movimento de *dutch roll*, nota-se que as variações de leme são elevadas, influenciando o rolamento e também que os *ailerons* influenciam a guinada devido à diferença de arrasto provocada. Ou seja, a entrada de leme provoca em β um leve amortecimento (decaimento), uma excitação em p e r e uma pequena

oscilação em ϕ , excitando todos os modos.

3.2 Treinamento da Rede Neural Artificial

Para identificar o modelo dinâmico da aeronave, foram usadas redes neurais artificiais recorrentes e com atrasos no tempo, pois têm apresentado resultados bastante satisfatórios em problemas deste nível. Primeiramente foi realizado um teste usando uma rede com uma rede recorrente com 1 camada intermediária com 12 neurônios nesta e 3 na de saída para poder fornecer

respostas das velocidades angulares p , q e r . Como entradas foram usados os sinais medidos em voo das variações de profundor, *ailerons* e leme das manobras *dutch-roll* e *short period*, devido ao fato de serem manobras mais complexas. As equações a seguir mostram os esquemas dos vetores de entrada e saída respectivamente.

$$\vec{u}(k) = \begin{bmatrix} \delta_a \text{ (degree)} \\ \delta_r \text{ (degree)} \\ \delta_e \text{ (degree)} \end{bmatrix},$$

$$\vec{y}(k) = \begin{bmatrix} p \text{ (deg/ s)} \\ q \text{ (deg/ s)} \\ r \text{ (d / s)} \end{bmatrix},$$

Devido à diferença de intervalos de tempos em que foram colhidas as respostas, para deixar os vetores de entradas com os mesmos números de pontos, foram usadas discretizações distintas nos sinais usados como entradas para a rede neural.

A seguir são apresentadas nas Figuras 2 e 3 as variações de ângulo de ataque e da velocidade da aeronave, referentes a manobra *dutch roll*. Durante o ensaio em voo, a velocidade foi medida em “nós” e foi feita uma transformação para deixá-la em Km/h. Serão mostradas as respostas referentes a esta manobra apenas para não deixar o trabalho extenso.




Figura 2. Variação de ângulo de ataque.




Figura 3. Variação de velocidade em Km/h.

As Figuras 4, 5 e 6 mostram, respectivamente, as variações de ψ que é ângulo de guinada, θ que é ângulo de arfagem e ϕ que é ângulo de rolamento. Nesta manobra, pode-se observar que ψ e ϕ variam significativamente, enquanto o ângulo de arfagem bem pouco.




Figura 4. Ângulo de rolamento.




Figura 5. Ângulo de guinada.




Figura 8. Entrada de leme.




Figura 6. Ângulo de arfagem.




Figura 9. Entrada de profundor.

São mostrados também, nas Figuras 7, 8 e 9, os gráficos das entradas de *aileron*, leme e profundor usadas nesta manobra, e se pode observar que as entradas mais relevantes nesta manobra são a entrada de leme e de aileron.




Figura 7. Entrada de aileron.

3.3 Resultados de treinamento

Foram feitos vários testes e a topologia da rede que melhor identificou as velocidades angulares para as manobras de *dutch roll* e *short period* usadas foi uma rede com três camadas, sendo uma camada de entrada, uma intermediária com 5 neurônios e uma de saída com 3 neurônios. Foram usadas 4 entradas atrasadas. A rede foi treinada somente com metade dos dados e para verificar a generalização, foram apresentados todos os dados. Pode-se observar que a rede neural identificou

satisfatoriamente as velocidades angulares após o treinamento. O erro atingiu ordem de 10^{-6} depois de 30 épocas e estabilizou. Para treinar, foi usado o algoritmo de *Backpropagation* com a técnica de otimização de *Levenberg-Maquardt*.

As Figuras 10 e 11 mostram o resultado da identificação do *dutch roll*

e de *short period*, respectivamente. As curvas em vermelho mostram os sinais obtidos em voo e as curvas azuis mostram resultados fornecidos pela rede neural, quando apresentados todos os pontos. Pode-se verificar que o resultado foi satisfatório.




Figura 10. Identificação das respostas de velocidades angulares do modo *dutch roll*.




Figura 11. Identificação das respostas de velocidades angulares do modo *short period*.

4 RESULTADOS DA IDENTIFICAÇÃO

Depois de verificado o treinamento, foram apresentados os dados das outras manobras realizadas pela aeronave como entrada para a rede neural e foi verificado que a rede neural capturou a dinâmica da aeronave, como se pode

observar nas Figuras a seguir. Destaca-se que todas as simulações com as redes neurais foram realizadas usando o Software Matlab[®]. Nas Figuras 12 e 13, estão apresentados os resultados da identificação das velocidades angulares das manobras *SHSS* e *Roll response* respectivamente.




Figura 12. Identificação das respostas de p , q e r referentes à manobra *SHSS*.




Figura 13. Identificação das respostas de p , q e r referentes à manobra *roll response*.

As Figuras 14 e 15 apresentam os resultados da identificação das respostas das manobras *Trim* e *Level*.




Figura 14. Identificação das respostas de p , q e r referentes à manobra *trim*.




Figura 15. Identificação das respostas de p , q e r referentes à manobra *level*.

4.1 Plano de fases

Visando analisar a estabilidade da aeronave durante realização das manobras, serão construídos os planos de fases dos ângulos versus suas respectivas velocidades angulares, ou seja, $(\theta$ e $\dot{\theta}$, ϕ e $\dot{\phi}$ e ψ e $\dot{\psi})$. Para isto, serão feitas algumas verificações visando analisar quão próximo $\dot{\theta}$ é da velocidade angular de arfagem q , $\dot{\phi}$ é da velocidade de guinada r e $\dot{\psi}$ da velocidade de rolamento p , sendo p , q e r obtidas em voo e $\dot{\theta}$, $\dot{\phi}$ e $\dot{\psi}$ implementadas usando as equações cinemáticas obtidas em Etkin (1996).

$$\begin{aligned}
 p &= \dot{\phi} - \psi \text{sen } \theta \\
 q &= \dot{\theta} \cos \phi + \dot{\psi} \cos \theta \text{sen } \phi \\
 r &= \dot{\psi} \cos \theta \cos \phi - \dot{\theta} \text{sen } \phi \\
 \dot{\phi} &= p + q(\text{sen } \phi + r \cos \phi) \tan \theta \\
 \dot{\theta} &= q \cos \phi - r \text{sen } \phi \\
 \dot{\psi} &= (q \text{sen } \phi + r \cos \phi) \sec \theta
 \end{aligned}$$

Comparando as velocidades angulares medidas em voo, com resultados de velocidades angulares obtidas analiticamente, pode-se concluir que elas foram bastante próximas, como mostram as Figuras 16, 17 e 18. Foram feitas estas comparações referentes a todas as manobras e em todos os resultados foram bastante próximos, porém, no trabalho estão mostradas comparações apenas referentes a dados da manobra *dutch roll*.




Figura 16. Comparação de q com $\dot{\theta}$




Figura 17. Comparação de r com $\dot{\phi}$




Figura 18. Comparação de p com $\dot{\psi}$

As figuras 19, 20 e 21 mostram os planos de fases plotados, mostrando realmente a estabilidade da aeronave na manobra. Novamente, serão mostrados resultados referente à manobra *dutch roll*. Com relação às outras manobras pode-se verificar também a tendência ao equilíbrio.




Figura 19. Plano de fases de $\dot{\phi}$ contra ϕ




Figura 20. Plano de fases de $\dot{\theta}$ contra θ




Figura 21. Plano de fases de $\dot{\psi}$ contra ψ

5 CONCLUSÕES

Foi apresentado um modelo neural para a identificação da dinâmica de aeronaves. Foram usados dados de ensaio em voo de uma aeronave regional, referentes a 6 conjuntos distintos de respostas de manobras realizadas. Em todas elas, a aeronave estava com trem de pouso recolhido e

flap 0. Foi usado para identificação um modelo neural recorrente e com atrasos no tempo, treinada com o algoritmo *Backpropagation* e com a técnica de otimização de *Levenberg-Maquardt*. Depois de vários testes realizados, foi usada uma rede neural com 4 atrasos na entrada e 5 e 3 neurônios nas camadas intermediária e de saída respectivamente. Como entradas para a rede neural, foram usadas as respostas referentes às manobras de *dutch roll* e de *short period*. As variações das superfícies de controle e as respostas de variação de velocidade angular p , q e r , formaram respectivamente dados dos vetores de entrada-saída. Pode-se observar que a rede neural identificou satisfatoriamente as velocidades angulares depois de treinadas, tendo maior dificuldade na identificação dos dados de voo trimado. Isto, provavelmente, foi causado pelo fato de que, como os dados das manobras foram medidos usando diferentes intervalos de tempo, os sinais de respostas foram discretizados usando diferentes intervalos visando deixar os vetores de entrada com mesmo comprimento e, portanto, tornar possível a realização das simulações com a rede neural.

REFERÊNCIAS

ETKIN, B.; REID, D.R. **Dynamics of flight: stability and control**, 3rd ed, John Wiley and Sons, 1996.

HAYKIN, S. **Neural Network: a Comprehensive Foundation**, Macmillan College Publishing Company, New York, 1994.

RODIN, E.Y.; AMIN, M. Prediction and Identification of Tactical Air Combat Maneuvers: Neural Network Implementation of a Qualitative Approach. In: AEROSPACE APPLICATIONS OF ARTIFICIAL INTELLIGENCE CONFERENCE, 5th. Dayton, 1989. **Proceedings...** Dayton, 1989.

SARAVANAN, N.; DUYAR, A. (1994). Modeling Space Shuttle Main Engine Using Feed-Forward Neural Networks. **Journal of Guidance, Control and Dynamics**, v. 17, n.4, p.641-648.

SOUZA, L. F. R. et al., 2005, Simulation and Identification of a Flight Envelope using Neural Networks. In: CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA. Ouro Preto, MG, Brazil. **Proceedings...** Ouro Preto, 2005.