

CONTROL DE UN VEHÍCULO CUATRIRROTOR BASADO EN REDES NEURONALES

Jesús Enrique Sierra
Universidad Complutense de Madrid, jesier01@ucm.es

Matilde Santos
Universidad Complutense de Madrid, msantos@ucm.es

Resumen

En este trabajo se propone una estrategia de control neuronal adaptativa para estabilizar un vehículo aéreo no tripulado (UAV). Se estudia la influencia de la masa del cuatrirrotor y de las perturbaciones. Los resultados muestran cómo el aprendizaje online hace más robusto el control, minimizando los efectos de las variaciones en la masa y de las perturbaciones externas en la altura.

Palabras Clave: Control neuronal, aprendizaje online, redes neuronales, vehículos aéreos no tripulados (UAV), cuatrirrotor.

1 INTRODUCCIÓN

En los últimos años han surgido nuevas y valiosas aplicaciones de los vehículos aéreos no tripulados en diferentes sectores como: defensa, seguridad, construcción, agricultura, lucha contra incendios, entretenimiento, mensajería, etc, que demandan el diseño de controladores eficientes y robustos que soporten estas u otras aplicaciones. Por ello el modelado y el control de estos sistemas inestables y complejos siguen motivando la investigación y el interés de la comunidad científica [1].

La modelización y el control de un vehículo aéreo no tripulado, UAV (*Unmanned Aerial Vehicle*), no es una tarea sencilla. Su complejidad proviene de diferentes fuentes: la aleatoriedad de los flujos de aire y de las fuerzas exógenas, la fuerte no linealidad de la dinámica del mismo, los acoplamientos en su dinámica, la incertidumbre de las medidas,... Estos factores convierten a las técnicas basadas en la inteligencia artificial en un camino prometedor para la identificación y el control de estos sistemas.

Estas técnicas resultan especialmente útiles cuando se producen modificaciones en parámetros del modelo mientras el sistema está en funcionamiento. Por ejemplo, variaciones en la masa total del sistema en los vehículos que se emplean en tareas logísticas,

donde la masa depende en cada momento de la paquetería que están transportando.

Existen otros trabajos que han aplicado redes neuronales al modelado de estos sistemas [2, 3] y también para el control [4, 5]. También se pueden encontrar ejemplos de la aplicación de estas técnicas inteligentes para modelar otros sistemas complejos no lineales [6], por ejemplo, vehículos marinos [7].

En este trabajo se propone una estrategia de control neuronal adaptativa para estabilizar un vehículo aéreo no tripulado (UAV). Se estudia la influencia de la masa del cuatrirrotor y de las perturbaciones. Los resultados muestran cómo el aprendizaje online hace más robusto el control, minimizando los efectos de las variaciones en la masa y de las perturbaciones externas en altura.



Figura 1: Vehículo cuatrirrotor.

La organización del documento es la siguiente. En la sección 2 se exponen las ecuaciones que describen el comportamiento dinámico del UAV. La sección 3 se destina al estudio de la estrategia de control neuronal adaptativa implementada. Los resultados son discutidos y comparados en la sección 4. El documento finaliza con las conclusiones y trabajos futuros.

2 DESCRIPCIÓN DEL SISTEMA

Un vehículo cuatrirrotor consta de cuatro brazos perpendiculares, cada uno de ellos con un motor y un rotor (figura 1). Los cuatro motores proporcionan

propulsión para el control de la sustentación así como el control de la dirección. El sistema consiste en dos pares de rotores opuestos entre sí: (1,3) y (2,4) (Figura 2). Para que esté balanceado un par gira hacia la derecha mientras que el otro gira hacia la izquierda. Un incremento de la velocidad del rotor 3 frente al rotor 1 produce un pitch positivo ($\theta > 0$), mientras que un incremento de velocidad del rotor 4 frente al 2, produce un roll positivo ($\phi > 0$) (Figura 2).




Figura 2: Sistema de coordenadas del UAV.

La posición absoluta es descrita por tres coordenadas (x, y, z) y su orientación por los tres ángulos de Euler (ϕ, θ, ψ), bajo las condiciones ($-\pi \leq \psi < \pi$) para el yaw, ($\frac{\pi}{2} \leq \phi < \frac{\pi}{2}$) para el roll y ($\frac{\pi}{2} \leq \theta < \frac{\pi}{2}$) para el pitch.

Usando el método de Newton-Euler la dinámica angular del sistema puede expresarse como:

$$\tau = J\dot{\omega} + \omega \times J\omega \quad (1)$$

$$J = \begin{pmatrix} I_x & 0 & 0 \\ 0 & I_y & 0 \\ 0 & 0 & I_z \end{pmatrix} \quad (2)$$

Donde τ es un vector de pares a lo largo de los tres ejes, J es el tensor de inercia, ω es un vector de velocidades angulares y \times denota el producto vectorial.

La dinámica de traslación se rige por la ecuación:

$$m\dot{v} = RT - mge_3 \quad (3)$$

Donde m es la masa del cuatrirotor, R es la matriz de rotación, g es la aceleración de la gravedad, T es el vector de fuerzas y $e_3 = [0,0,1]^T$ es un vector unitario que describe la orientación del rotor.

Los vectores τ y T , vienen dados por las velocidades de giro de los rotores:

$$\tau = \begin{pmatrix} bl(\Omega_4^2 - \Omega_2^2) \\ bl(\Omega_3^2 - \Omega_1^2) \\ d(\Omega_2^2 + \Omega_4^2 - \Omega_1^2 - \Omega_3^2) \end{pmatrix} \quad (4)$$

$$T = \begin{pmatrix} 0 \\ 0 \\ b(\Omega_1^2 + \Omega_2^2 + \Omega_3^2 + \Omega_4^2) \end{pmatrix} \quad (5)$$

En las ecuaciones 4 y 5, b es el coeficiente de empuje, d es el coeficiente de arrastre y l es la longitud de cada brazo; $\Omega_1, \dots, \Omega_4$ son las velocidades de los rotores 1 a 4, respectivamente.

Para simplificar, en vez de utilizar las velocidades de los rotores se pueden utilizar las señales de control u_1, u_2, u_3 y u_4 , que se obtienen de la transformación:

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 0 & -1 & 0 & 1 \\ -1 & 0 & 1 & 0 \\ 1 & -1 & 1 & -1 \end{bmatrix} \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} \quad (6)$$

Esta matriz es invertible por lo que a partir de señales de control pueden generarse consignas de velocidad de los rotores.

Usando las ecuaciones 1 a 6, se llega al siguiente sistema de ecuaciones:

$$\ddot{\phi} = \dot{\theta}\dot{\psi}(I_y - I_z)/I_x + (lb/I_x)u_2 \quad (7)$$

$$\ddot{\theta} = \dot{\phi}\dot{\psi}(I_z - I_x)/I_y + (lb/I_y)u_3 \quad (8)$$

$$\ddot{\psi} = \dot{\phi}\dot{\theta}(I_x - I_y)/I_z + (d/I_z)u_4 \quad (9)$$

$$\ddot{X} = -(\sin\theta\cos\phi)(b/m)u_1 \quad (10)$$

$$\ddot{Y} = (\sin\phi)(b/m)u_1 \quad (11)$$

$$\ddot{Z} = -g + (\cos\theta\cos\phi)(b/m)u_1 \quad (12)$$

Las constantes empleadas para las simulaciones (Tabla 1) se han extraído de [8].

Tabla 1: Constantes empleadas en el modelo.

Parámetro	Descripción	Valor
l	longitud	0.232 m
m	Masa del cuatrirotor	0.52 Kg
d	Coficiente de arrastre	$7.5e-7$ N m s ²
b	Coficiente de empuje	$3.13e-5$ N s ²
I_x	Inercia en X	$6.228e-3$ Kg m ²
I_y	Inercia en Y	$6.225e-3$ Kg m ²
I_z	Inercia en Z	$1.121e-2$ Kg m ²

3 DESCRIPCIÓN DEL CONTROLADOR NEURONAL

3.1 ESTRATEGIA DE CONTROL

Existen diferentes estrategias a la hora de emplear las redes neuronales para controlar sistemas. En este caso hemos empleado una variante de la estrategia de aprendizaje generalizado (GLA), refinando la red en tiempo real mediante un aprendizaje adaptativo [9].

En una primera fase se aplica la estrategia de aprendizaje generalizado, entrenando la red offline para identificar la inversa de la planta (Figura 3).

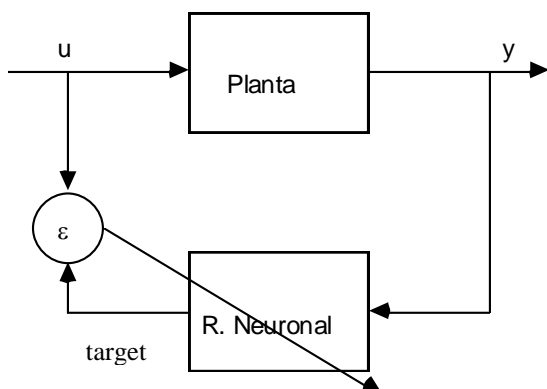


Figura 3: Fase de entrenamiento offline para identificación de la planta.

La red neuronal que sirve de controlador debe actuar como la inversa de la planta, es decir, que a partir de la respuesta deseada (la señal de referencia r) calcule la señal de control u que conduzca a la salida real del sistema y a la señal de referencia.

Una vez que la red se ha entrenado offline, se coloca la red en cascada con la planta. Después se refina la configuración de la red online. Para ello, en cada intervalo de control se ejecutan secuencialmente dos procesos en la red:

1. **Simulación:** A partir de la referencia de entrada se obtiene la salida u que se lleva a la planta a la referencia (Figura 4, conmutador en la posición superior).
2. **Aprendizaje:** A partir de las salidas de la planta y anteriores se entrena la red neuronal para generar la salida de control u . (Figura 4, conmutador en la posición inferior).




Figura 4: Fase de control + aprendizaje online.

3.2 CONTROL DE ALTITUD

Para comprobar la validez de la técnica nos hemos centrado en la regulación de la altitud. Los cuatrirtores normalmente vienen equipados con acelerómetros, por lo que se supone medible la aceleración en el eje Z (\ddot{Z}).

En este caso, la red debe ser capaz de simular la señal de control u_1 a partir de las medidas de aceleración. El conjunto de datos de entrada de la red se forma, en cada instante de tiempo t , con el valor de la señal de control u en los 10 instantes de muestreo anteriores, $u(t - iT_s)$ donde $i = 1 \dots 10$, y T_s es tiempo de muestreo, y el valor de la aceleración del eje Z en el instante actual $\ddot{Z}(t)$. El conjunto de datos objetivo se ha generado con el valor de la señal de control u_1 en el instante actual $u_1(t)$. El T_s empleado en los experimentos ha sido 10ms.

Para controlar la altura Z se añade un controlador PID que genera las consignas necesarias de aceleración en el eje Z . La figura 5 refleja el sistema de control completo propuesto.




Figura 5: Controlador de altitud propuesto.

Para entrenar la red durante la fase offline se generan trenes de pulsos de amplitud variable durante 4 segundos. Previamente al entrenamiento los conjuntos de entrada y salida son normalizados para ajustar el rango a 0-1. La aplicación de esta técnica en un sistema real, requeriría la supervisión de los pulsos por un piloto, quién se encargaría de ajustar las amplitudes para no deteriorar el sistema.

En el estudio se ha empleado como red neuronal un perceptrón multicapa (MLP) con 5 capas ocultas (Figura 6). El algoritmo de optimización empleado ha sido el Levenberg-Marquardt con $\mu = 0.001$.




Fig. 6. Esquema de la red neuronal empleada.

En la figura 7 puede apreciarse cómo la salida de la red se aproxima de una manera bastante fiel a la dinámica inversa de la planta tras el entrenamiento offline.




Figura 7: Entrenamiento offline de la red

4 RESULTADOS

Los resultados que se presentan se han obtenido mediante simulación empleando el software Matlab/Simulink. Las simulaciones duran 15 segundos; durante los 4 primeros se entrena el controlador offline y en los restantes 11 segundos se aplica el aprendizaje, introduciendo al controlador como entrada la consigna Z_{ref} .

En la figura 8 puede observarse el comportamiento de las distintas fases del controlador. En el eje x se representa el tiempo y en el eje y se representan: la aceleración en Z del sistema (en azul), la consigna de aceleración generada por el controlador una vez entrenado (en verde), y la altitud (en rojo).

Hasta el segundo 4 el controlador está siendo entrenado. Por este motivo, la gráfica en verde vale 0 ese instante. Las señales de control que se emplean para entrenar al controlador provocan que la altitud del sistema varíe. En el instante $t = 4$, el controlador deja de ser entrenado y pasa a la fase de control. En ese momento se fija el valor 2 como referencia para la altura Z. Se empiezan a generar consignas de aceleración para estabilizar la altitud en torno a ese valor. En esta figura 8 también es interesante ver que las señales $acelRef$ (entrada de la red neuronal) y $acelZ$ (salida del sistema) se parecen cada vez más conforme pasa el tiempo gracias al aprendizaje online.




Figura 8: Fases del controlador de altitud propuesto.




Figura 9: Altitud con aprendizaje online.

En la figura 9 se muestra en azul la altura real del UAV y en verde la referencia. Puede apreciarse como el controlador consigue estabilizar la señal de altitud entorno al valor deseado.

Estos resultado podrían extenderse al control de los tres ángulos de Euler del UAV, para el seguimiento de una trayectoria.

4.1 VARIACIÓN DE LA MASA DEL SISTEMA

Se simula ahora el sistema introduciendo un cambio en la masa (se duplica) del cuatrirotor en el instante 6. Puede observarse en las figuras 10 y 11 cómo el sistema con aprendizaje online consigue aproximar la referencia (verde) mientras que en el sistema sin aprendizaje el error estacionario es notable.




Fig. 10 . Simulación de la señal de control u_1 con aprendizaje online y variación de la masa.




Fig. 11. Simulación de la señal de control u_1 sin aprendizaje y variación en masa.

La figura 12 representa la referencia de altitud (en verde) y las señales de altitud con y sin aprendizaje online (azul y rojo respectivamente). El error en la salida de la red neuronal mostrado en la figura 11 se traduce en una peor respuesta a un escalón en la altura. En este caso aumenta el sobreimpulso y el error estacionario es grande.




Fig. 12. Comparación del control de altitud con y sin aprendizaje online ante una perturbación.

4.2 INFLUENCIA DE PERTURBACIONES EXTERNAS

El efecto de una perturbación en la ecuación 12 se ha introducido como:

$$\ddot{Z} = -pert - g + (\cos\theta\cos\phi) (b/m)u_1 \quad (13)$$

En esta simulación se aplica una perturbación de 9.8 m/s^2 en el instante 6. Puede observarse en las figuras 13 y 14 cómo el sistema con aprendizaje online consigue aproximar la referencia (en verde) sin error apreciable mientras que en el sistema sin aprendizaje adaptativo produce error estacionario.




Fig. 13. Simulación de la señal de control u_1 con aprendizaje online y perturbación externa.




Fig. 14. Simulación de la señal de control u_1 sin aprendizaje online y perturbación externa.

La figura 15 representa la referencia de altitud (en verde) y la altura del UAV con y sin aprendizaje online (azul y rojo, respectivamente). El error en la salida de la red neuronal observable en la figura 14 se traduce en una peor respuesta a un escalón. En este caso aumenta el sobreimpulso y el error estacionario es mayor que en el caso de variación de la masa (Figura 12).




Fig. 15. Comparación del control de altitud con y sin aprendizaje online ante una perturbación.

5 CONCLUSIONES

Los UAV son sistemas complejos de modelar y controlar. La dificultad estriba en la aleatoriedad de las perturbaciones y en su dinámica fuertemente no lineal.

En este trabajo se ha mostrado cómo la aplicación de una técnica de la Inteligencia Artificial, en concreto las redes de neuronas artificiales, se pueden aplicar para diseñar un sistema de control neuronal que sea eficiente.

Se ha validado la propuesta en simulación para el control de la altura de un UAV. Se ha mostrado cómo el aprendizaje adaptativo de la red (online) permite un control capaz de hacer frente a variaciones en la masa del sistema o a perturbaciones externas constantes en la aceleración.

Como trabajos futuros se plantean, por un lado, controlar el sistema completo para considerar los acoplamientos entre sus variables y, por otro, añadir modelos más realistas de perturbaciones.

Agradecimientos

El autor J.E. Sierra agradece a la empresa ASTI la financiación de la presentación de este trabajo en las Jornadas de Automática 2017.

Referencias

- [1] Zulu, A., & John, S. (2016). A review of control algorithms for autonomous quadrotors. arXiv preprint arXiv:1602.02622
- [2] Sierra, J.E. & Santos, M. (2017). Modeling engineering systems using analytical and neural techniques: hybridization. *Neurocomputing*.

- [3] Bansal, S., Akametalu, A. K., Jiang, F. J., Laine, F., & Tomlin, C. J. (2016). Learning quadrotor dynamics using neural network for flight control. In: *Decision and Control (CDC), 2016 IEEE 55th Conf. on* (pp. 4653-4660).
- [4] Boudjedir, H., Bouhali, O., & Rizoug, N. (2014). Adaptive neural network control based on neural observer for quadrotor unmanned aerial vehicle. *Advanced Robotics*, 28(17), 1151-1164.
- [5] Bakshi, N. A., & Ramachandran, R. (2016). Indirect model reference adaptive control of quadrotor UAVs using neural networks. In: *Intelligent Systems and Control (ISCO), 2016 10th Int. Conf. on* (pp. 1-6).
- [6] Santos, M. (2011). Aplicaciones Exitosas de Control Inteligente a Casos Reales. *Science Direct, Revista Iberoamericana de Automática e Informática Industrial*.
- [7] Santos, M., López, R., & De La Cruz, J. M. (2006). A neuro-fuzzy approach to fast ferry vertical motion modelling. *Engineering Applications of Artificial Intelligence*, 19(3), 313-321.
- [8] S. Bouabdallah, S. and Siegwart, R. (2006) *Advances in Telerobotics*, chapter Towards Intelligent Miniature Flying Robots, pp. 429-440.
- [9] Wise, K. A., Lavretsky, E., & Hovakimyan, N. (2006, June). Adaptive control of flight: theory, applications, and open problems. In *American Control Conference, 2006* (pp. 6-pp). IEEE.