



**UNIVERSIDAD  
CARLOS III DE MADRID**

# **CONTROL INTELIGENTE**

## **CONTROL DE ÁNGULO PITCH DE UN HELICÓPTERO CON REDES NEURONALES**

**Profesores: Luis Enrique Moreno Lorente  
Luis Santiago Garrido Bullón  
Dorin Sabin Copaci**

---

## ÍNDICE

---

### Control por Redes Neuronales - Proyecto 3

1. Introducción.....	2
2. Selección y explicación del sistema .....	2
3. Objetivos .....	4
4. Inicialización del sistema. Tuning de la matriz de desacoplo SOF .....	5
5. Etapa 1: Identificación del sistema .....	8
6. Etapa 2: Entrenamiento de la Red Neuronal .....	11
7. Etapa 3: Control del sistema. Evaluación de resultados .....	13
8. Evolución del método expuesto .....	15
Prueba de control 1 .....	15
Prueba de control 2 .....	16
Prueba de control 3 .....	17
Prueba de control 4 .....	18
Prueba de control final .....	19
9. Conclusiones .....	19

# 1. INTRODUCCIÓN

En el presente proyecto se procede a la elaboración de un controlador mediante la red neuronal implementada en Simulink. Se dispone de tres modelos de redes neuronales propuestos: NN Predictive, Narmal-L2 y Model Reference. Se ha seleccionado para el proyecto la red Narma-L2 debido a que es el sistema neuronal del que más prácticas se han acumulado, y del que se espera sacar mayor provecho.

Para generar el control se realizará una primera etapa de identificación de la planta, una segunda etapa de aprendizaje y una etapa final donde se estudiará el controlador de la red. Dicho controlador se aplicará a un sistema no lineal para demostrar la potencia de las redes neuronales y su rápida resolución para problemas de baja linealidad.

# 2. SELECCIÓN Y EXPLICACIÓN DEL SISTEMA

Para este tercer proyecto se ha elegido el sistema **rct\_helico**. Entre todos los sistemas disponibles se ha elegido este último debido a que presenta una gran comodidad de estudio. Todos los bloques se muestran en el diagrama único y no hay subetapas que queden escondidas.

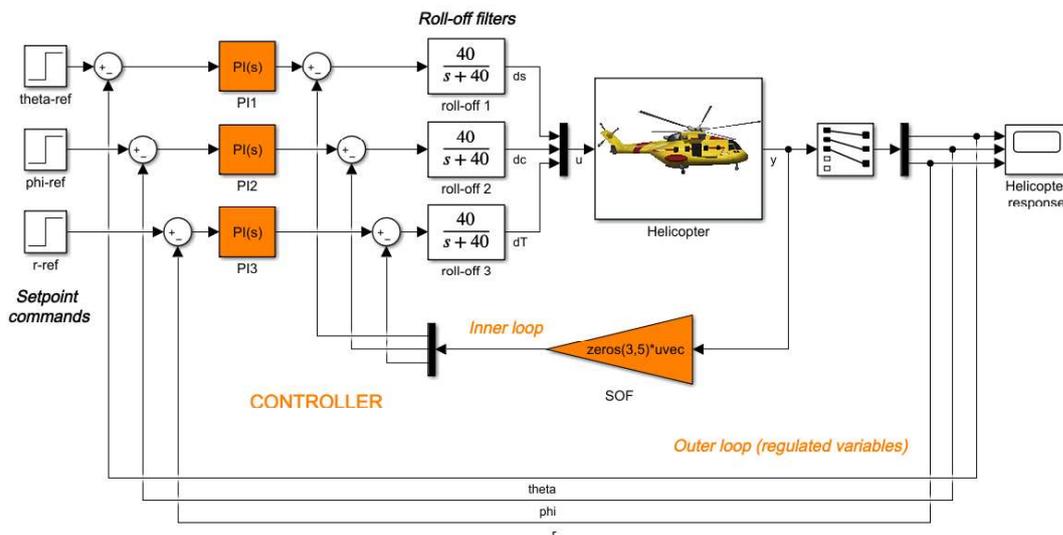


Figura 1: Sistema rct\_helico

El sistema cuenta con tres entradas correspondientes a los actuadores sobre los grados de libertad de rotación de un helicóptero convencional: theta (pitch), phi (roll), r (yaw).

Las tres salidas o respuestas del sistema son la posición del helicóptero con respecto a estos tres ángulos.

Justo a continuación de las entradas contamos con tres filtros de Roll-off, uno por cada entrada. Estos filtros de paso bajo se encargan de eliminar el posible ruido generado o recibido a la salida de los actuadores, y tienen como función evitar rápidas oscilaciones en la respuesta del helicóptero. Sin embargo, estos filtros son prescindibles y alargan enormemente el tiempo de identificación de la planta, por lo que serán eliminados.

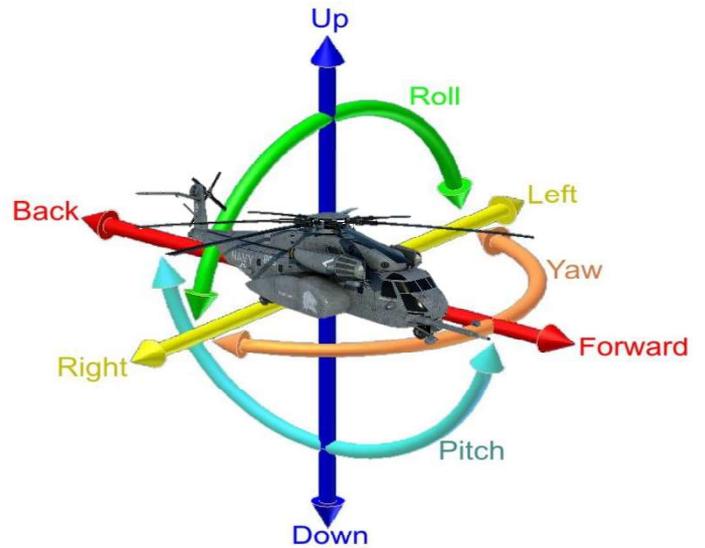


Figura 2: Diagrama de Pitch, Roll y Yaw

El bloque de ganancias SOF es una matriz de desacoplo de 3 x 5 inicializada a cero que se encarga de redistribuir las 5 salidas del helicóptero a las 3 entradas y actúa a su vez de primer feedback del sistema. Como inicialmente este bloque vale cero, anula completamente la realimentación interna del sistema, luego será el primer bloque que ajustaremos en una sesión de Tuning para que la red neuronal sea capaz de controlar el sistema. Con este bloque iniciado a cero es imposible realiza ningún control.

Finalmente, el boque del helicóptero representa la planta de la aeronave. Al no tener una función de transferencia se comporta como un sistema no lineal.

### 3. OBJETIVOS

Al contrario que en el modelado de sistemas en el espacio de estados donde se trabaja con múltiples entradas y salidas, en el presente proyecto se tratará con controladores con entrada y salida únicas. De esta forma, y aunque el helicóptero cuente con tres entradas y tres salidas, se va a realizar el control del cabeceo o pitch (representado por theta) de la aeronave dejando a un lado el escorado (roll, phi) y la rotación (yaw, r). El sistema rct\_helico personalizado es el siguiente, donde se ha destacado en azul la rama que va a ser controlada:

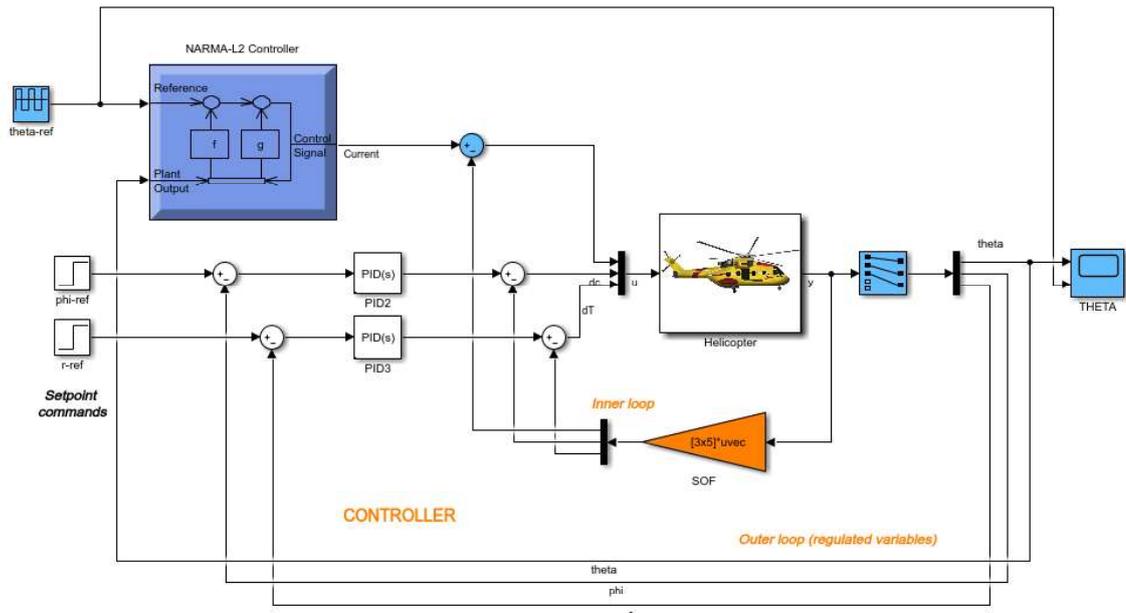


Figura 3: Sistema rct\_helico personalizado

En el momento de establecer los objetivos se ha considerado el sistema como si se tratase de una aeronave real. Por ello, los valores de sobreoscilación, tiempo de establecimiento y estabilidad deseados se han seleccionado de forma rigurosa y justificada:

- Sobreoscilación restringida a un máximo de 2 %. En un helicóptero real la sobreoscilación es un gran problema ya que puede inducir a la desestabilización de la aeronave y su consecuente caída. Es mucho más seguro un sistema sin sobreoscilación por lo que en el proyecto se enfocará en reducir este parámetro hasta un máximo del 2%.
- Tiempo de establecimiento menor de 1 segundo. Aunque un helicóptero sea un sistema relativamente lento (mucho más lento que un motor DC o una carga/descarga de un condensador etc.) se requiere de una respuesta suficientemente rápida como para ser manejado con comodidad.
- Error de posición nulo. No se permite error en régimen permanente, un helicóptero profesional debe carecer de error en el momento de ubicar la aeronave.
- Estabilidad total. En ningún momento se puede permitir una pérdida de estabilidad ya que conduciría sin remedio a la caída de la aeronave.

## 4. INICIALIZACIÓN DEL SISTEMA. TUNNING DE LA MATRIZ DE DESACOPLO SOF

La herramienta del Tunner de Simulink es increíblemente útil para modificar los bloques del diagrama y así marcar condiciones en la respuesta del sistema.

Se procederá al autoajuste de las matriz de desacoplo SOF a través la herramienta de Analysis > Control Desing > Control System Tunner. Una vez se haya determinado el valor final de ésta, el sistema queda listo para ser controlado.

En primer lugar, al Tunner hay que especificarle los bloques a modificar. Como se mencionó en la descripción de los bloques, la matriz de desacoplo SOF comienza inicializada a cero. El objetivo de esta sesión es obtener unos valores que representen magnitudes razonables en la matriz SOF. Para saber si los valores son razonables se comprobará si es posible controlar el sistema con un controlador PID con ganancias de órdenes no desorbitados. Si con un controlador PID con ganancias entre -20 y 20 se puede controlar el ángulo de cabeceo theta significará que los valores de la matriz SOF están dentro de lo permitido. Al fin y al cabo, la matriz SOF confiere una propiedad única a cada sistema rct\_helico.

Para su auto ajuste se han introducido los bloques a cambiar y algunas metas para crear una respuesta sencilla.

Finalmente, la sesión del Tuner es la siguiente:

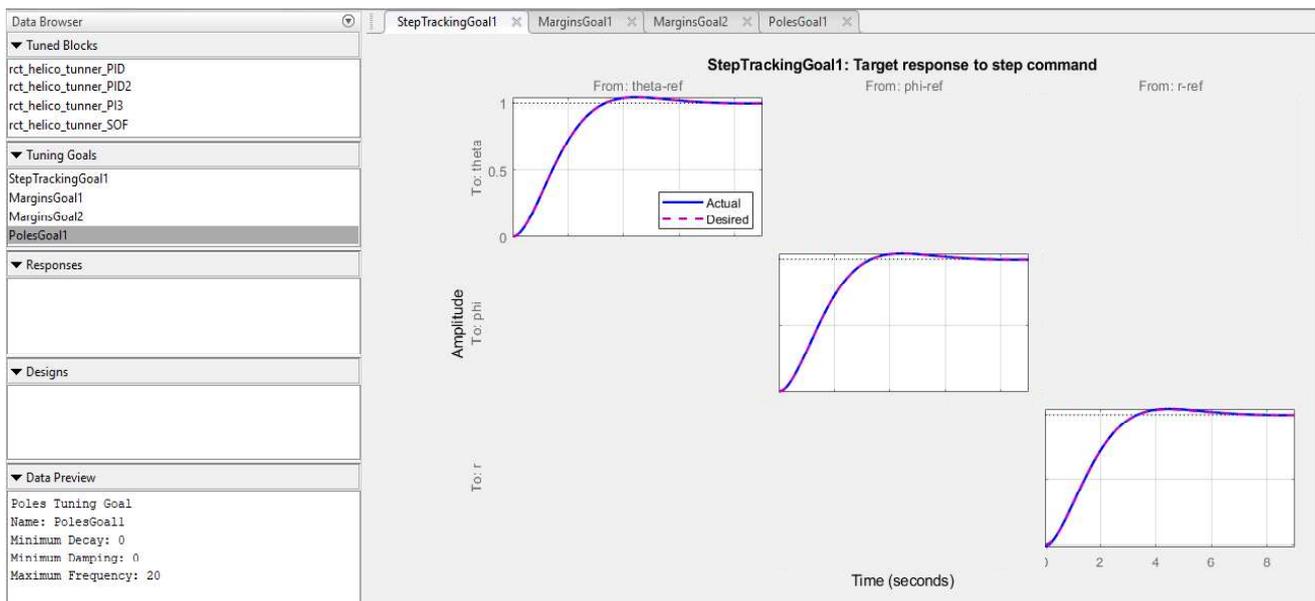


Figura 4: Sesión de Tunning de los controladores PID y matriz de desacoplo SOF

Como objetivos se han marcado:

- Una respuesta de segundo orden con una sobreoscilación del 4.3 % una tasa de error del 1%.

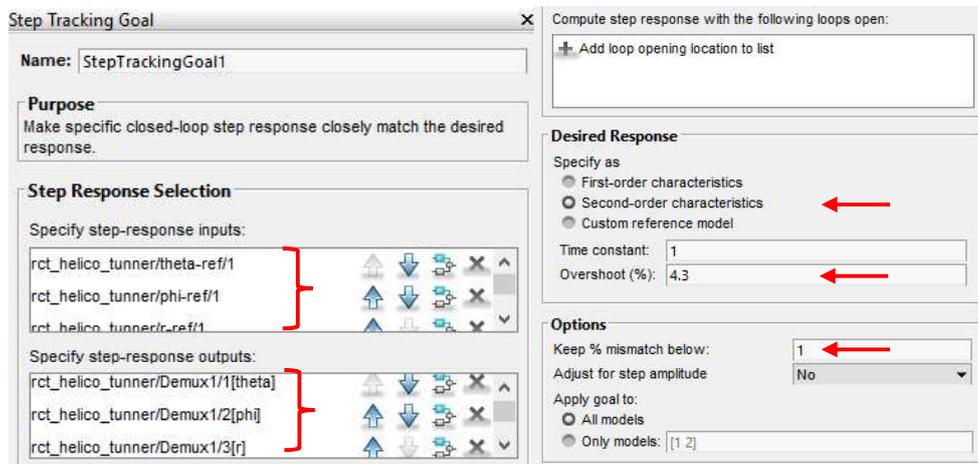


Figura 5: Objetivo de sobreoscilación

- Un margen de fase de 40° para garantizar la estabilidad total en las entradas y salidas del bloque del helicóptero con un margen de ganancia de 5 dB.

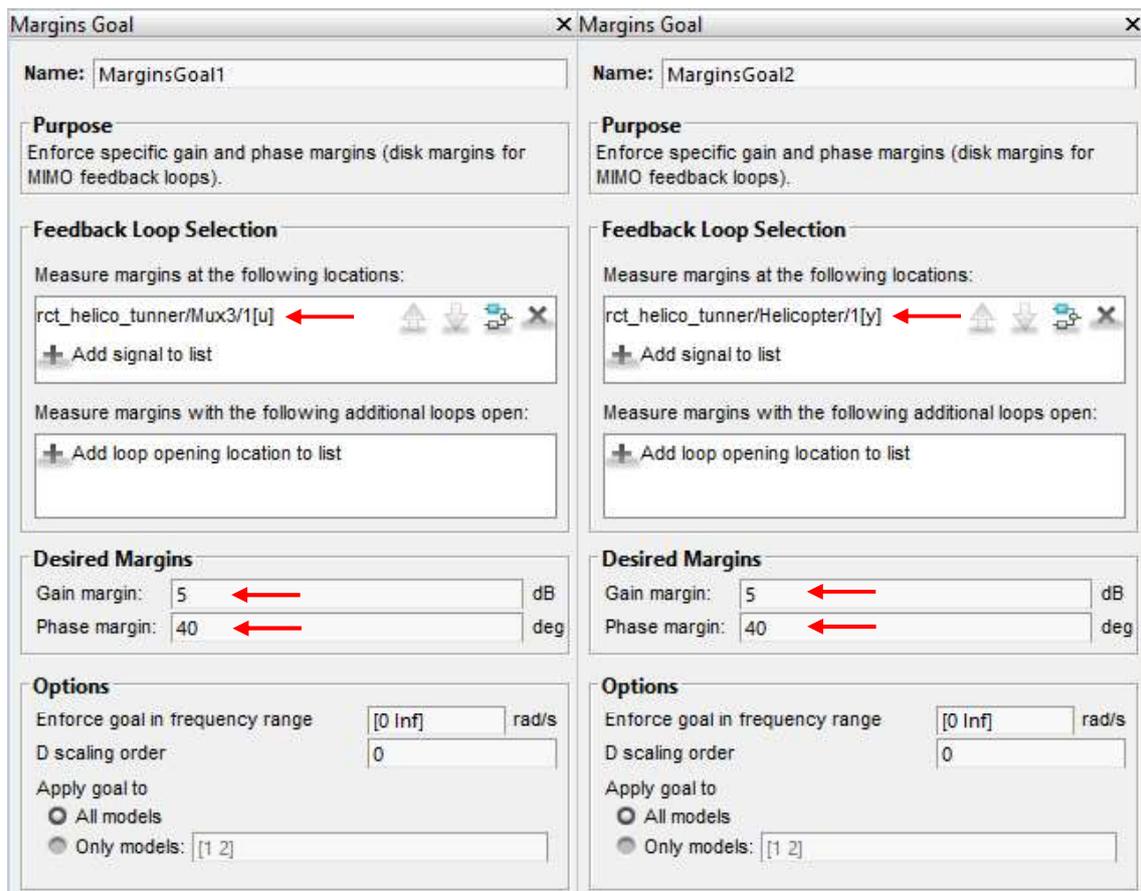


Figura 6: Ajuste de margen de fase y ganancia

- Una frecuencia natural de 20 rad/s para situar la ubicación de los polos en el semieje negativo.

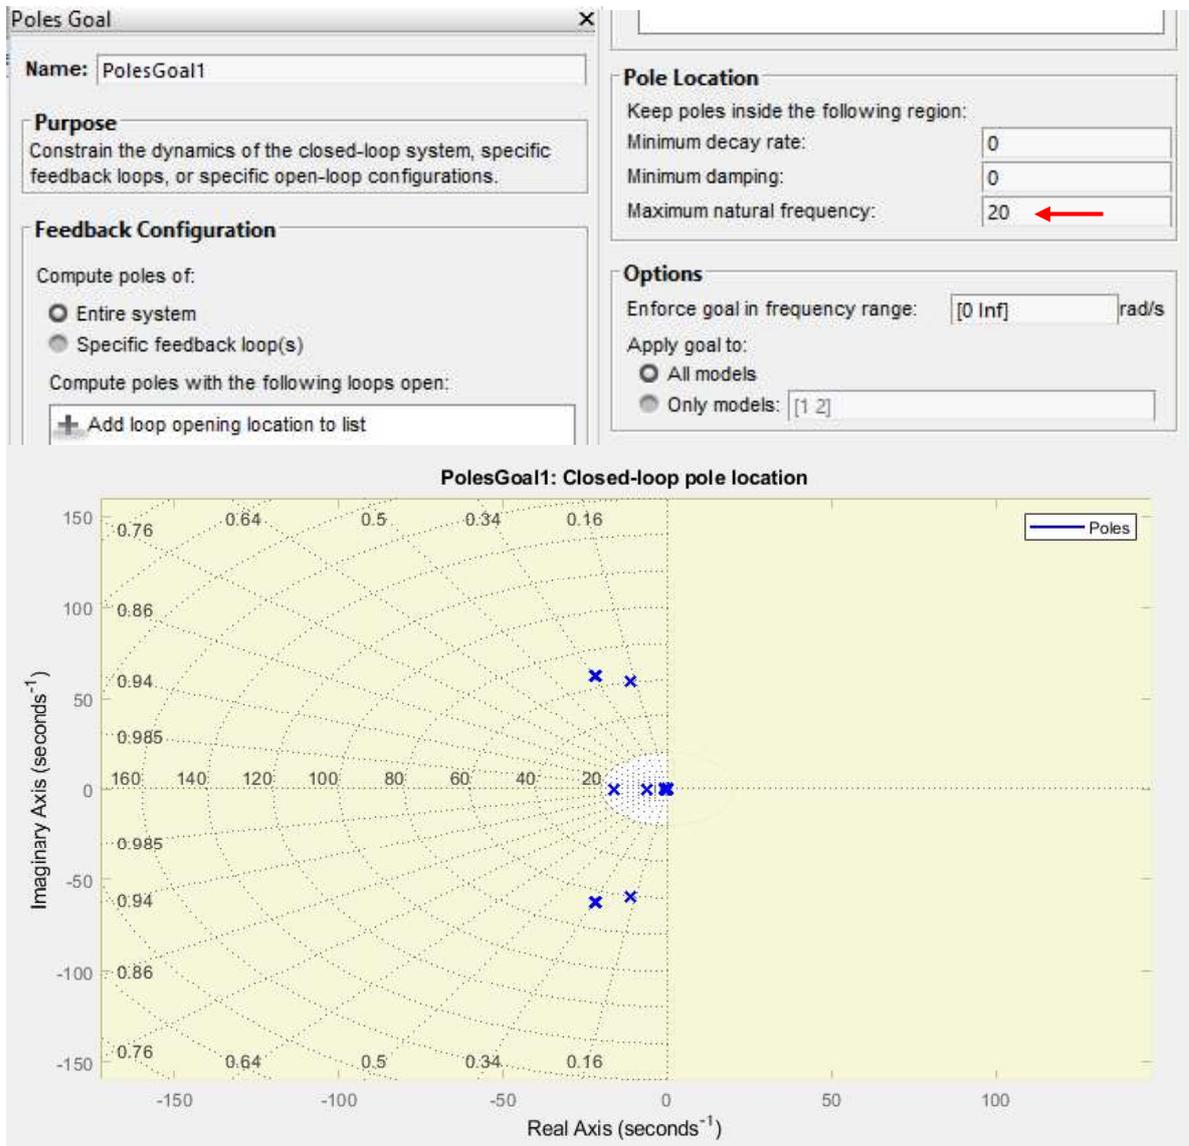


Figura 7: Ubicación de los polos de la respuesta deseada

Una vez completados los ajustes se actualizan los bloques de Simulink y se analizan los resultados. La aplicación actualiza los tres PID y la matriz de desacoplo SOF, sin embargo, se ignorarán los dos PID que no controlan el cabeceo de la aeronave. Los valores obtenidos del controlador PID y de la matriz de desacople son de un orden razonable.

$$\text{SOF} = \begin{bmatrix} 18.07 & 0.01 & 0.02 & 3.09 & 0.07 \\ 0.001 & 10.10 & 0.16 & 0.16 & 0.063 \\ 0.005 & -0.03 & -10.85 & 0.03 & 0.038 \end{bmatrix}$$

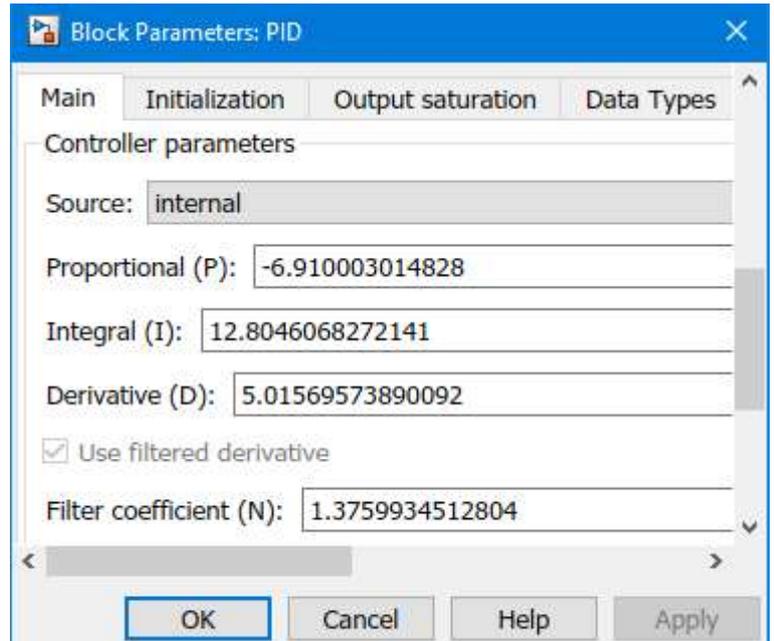
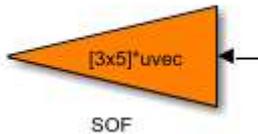


Figura 8: Tuning del controlador PID

La correspondiente respuesta frente a la entrada escalón unitaria es la siguiente:

Gracias al Tuner de Simulink se ha podido establecer la sobreoscilación exacta de 4.3%, tiempo de establecimiento de 6 segundos aproximadamente (2% de diferencia con el valor a mantener) y sin error en régimen permanente.

Esta sesión ha cumplido su objetivo. Ahora se dispone de una matriz de desacoplo SOF con unos valores razonables. El sistema está listo para la implementación de la red neuronal Narma-L2.

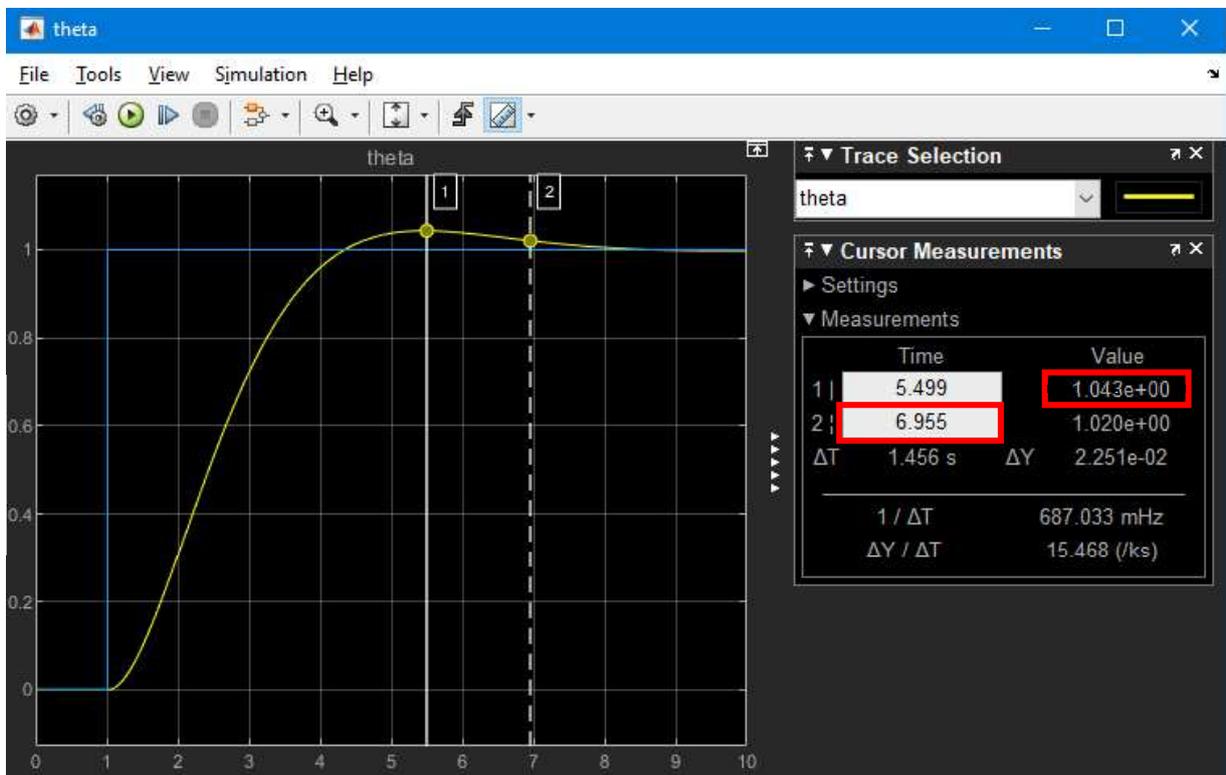


Figura 9: Cabeceo del sistema frente a la entrada escalón

Dado que se trata de un sistema no lineal, se ha ajustado el número de entradas y salidas retardada del sistema a cinco cada una. De esta forma, en vez de hacer un estudio lineal entre una única entrada y una única salida, se establecerá un grupo de 1 entrada y 3 salidas retardadas para que la red establezca sobre ello las relaciones necesarias y así, predecir cómo va a comportarse la planta del sistema con este conjunto de datos.

La red del bloque Narma cuenta con una capa oculta. Inicialmente, se establecerán 10 neuronas para la capa oculta y, en caso de no obtener una respuesta del sistema suficientemente buena, se aumentarán estas neuronas para que la red sea capaz de procesar más información.

Como se ha visto en los trabajos anteriores, el sistema rct\_helico responde con una rapidez no muy elevada. El orden de magnitud temporal para apreciar los cambios en la respuesta del sistema es de medio segundo (por ejemplo, otros sistemas como las cargas/descargas de condensadores tienen un orden temporal de milisegundos o hasta microsegundos). Por se realizará el intervalo de muestreo a 0.005 segundos, dos órdenes de magnitud más pequeño para verificar que no se está perdiendo información en el muestreo.

Se realizarán 6000 muestras para identificar la planta del sistema. Estas iteraciones se harán sobre el sistema mostrado en la Figura 0.

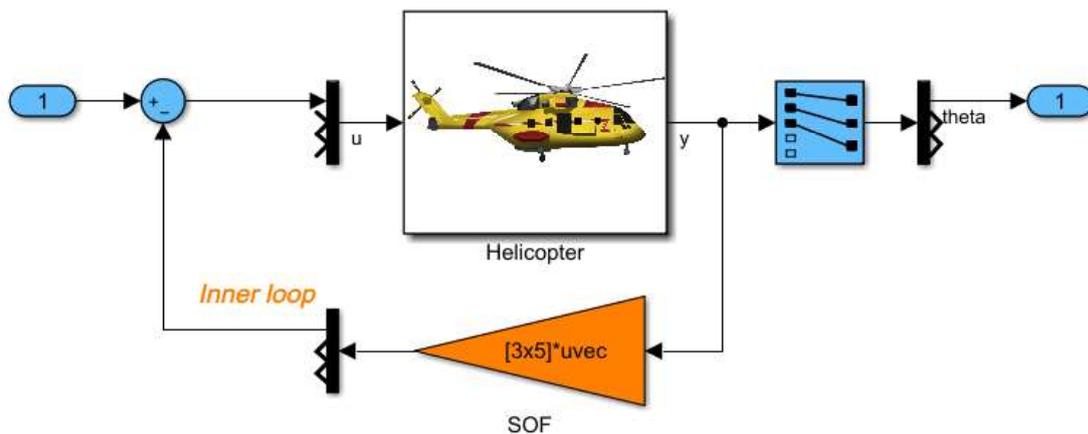


Figura 10: Planta del sistema

Dado que el orden de magnitud temporal es de 0.5 segundos (como se acaba de explicar), los pulsos de identificación del sistema se han ajustado entre 0.01 y 1 segundo de duración para cubrir un amplio rango de respuestas del sistema.

La amplitud de estos pulsos se ha ajustado entre -20 y 20. El motivo de ajustarlo a estos valores es porque, si la identificación se realizaba entre -1 y 1, la respuesta quedaba atenuada

por un factor de 18. Por ello, con los límites entre -20 y 20, la identificación del sistema contará con la magnitud suficiente como para que no se atenúe la respuesta.

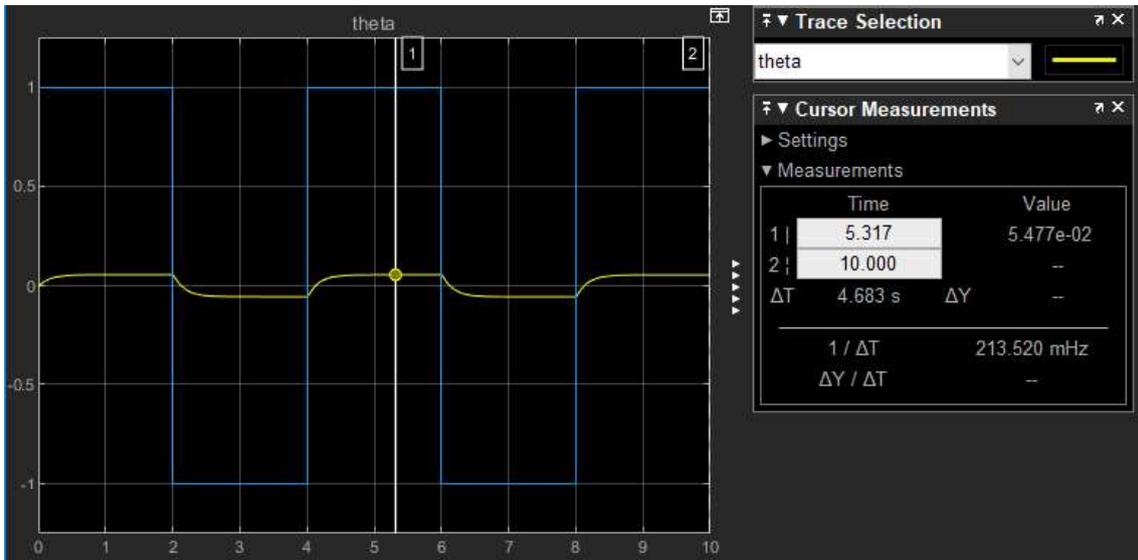


Figura 11: Respuesta atenuada

Finalmente, los datos para la identificación de la planta son los siguientes:

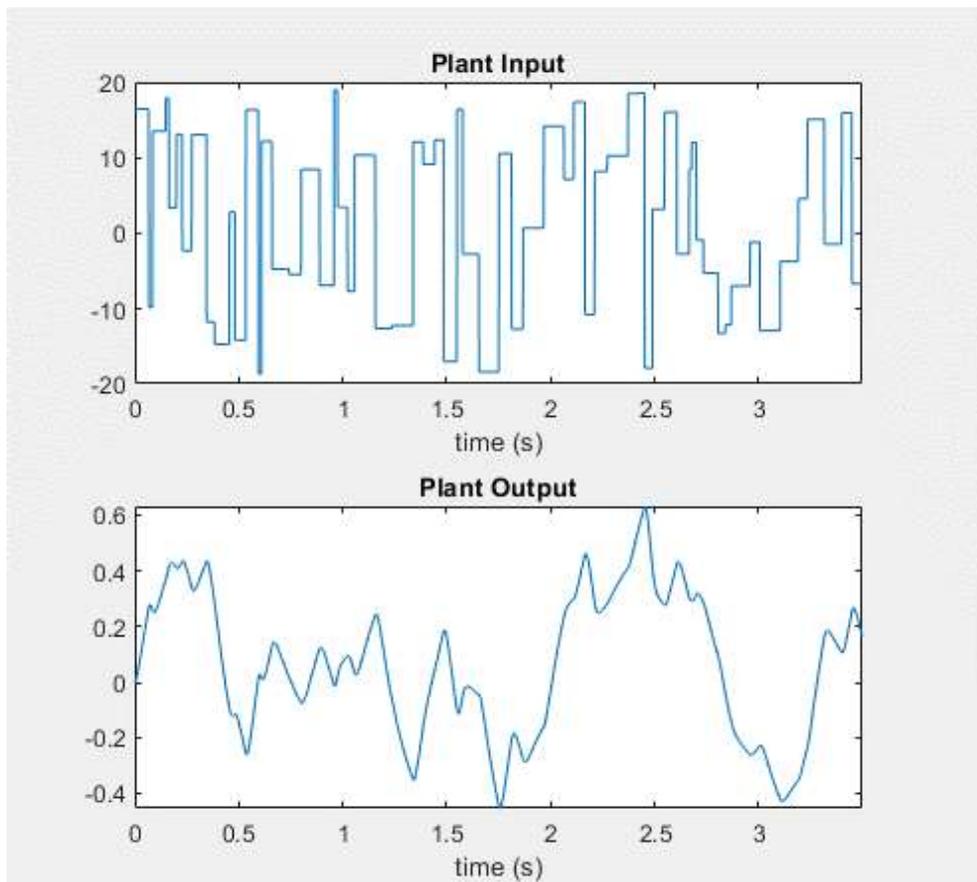


Figura 12: Datos de identificación de la planta

## 6. ETAPA 2: ENTRENAMIENTO DE LA RED NEURONAL

Una vez se dispone de una cantidad de suficiente de datos como para poder replicar el comportamiento de la planta del sistema se procede al entrenamiento de la red neuronal. Para ello se presta atención a los parámetros de entrenamiento. Se ha eliminado la opción de entrenar con los pesos actuales para evitar que cada prueba influya en la siguiente. Tras entrenar la red, se ha comprobado que el error entre la planta simulada y la real sea el más bajo posible.

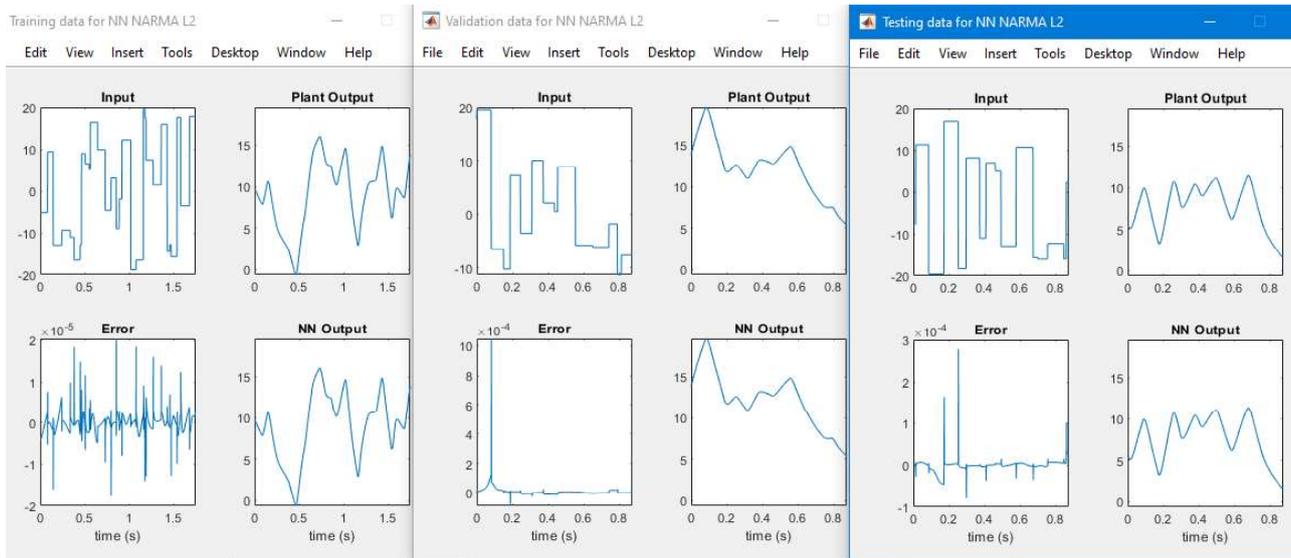


Figura 13: Datos de entrenamiento, validación y prueba de la red

Tanto en los datos de entrenamiento, como en la validación y en la prueba, las salidas reales y simuladas son prácticamente las mismas.

A continuación, se comprueba que el error final quede muy inferior a  $10^{-6}$  para considerarlo despreciable y que la regresión sea lo más cercana a 1.

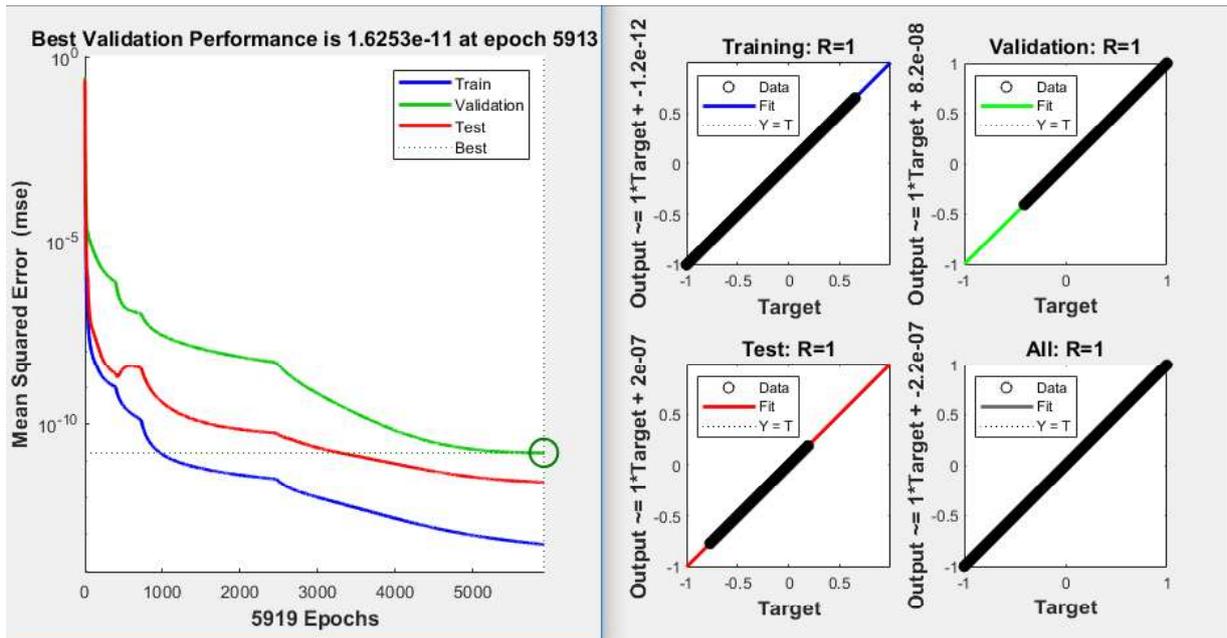


Figura 14: Performance y regresión del entrenamiento

El error global del sistema es menor que  $10^{-10}$ , algo indudablemente mejor de lo planteado ya que queda varios ordenes de magnitud inferior a  $10^{-6}$ . La regresión es 1 por lo que el aprendizaje ha sido exitoso y la red neuronal está lista para controlar el sistema. La red ha necesitado 5913 épocas hasta que ha sido incapaz de minimizar más el error.

## 7. ETAPA 3: CONTROL DEL SISTEMA. EVALUACIÓN DE RESULTADOS

Tras aplicar los cambios, el bloque Narma-L2 está listo para usarse como controlador. La respuesta que se obtiene para pulsos unitarios positivos y negativos es la siguiente:

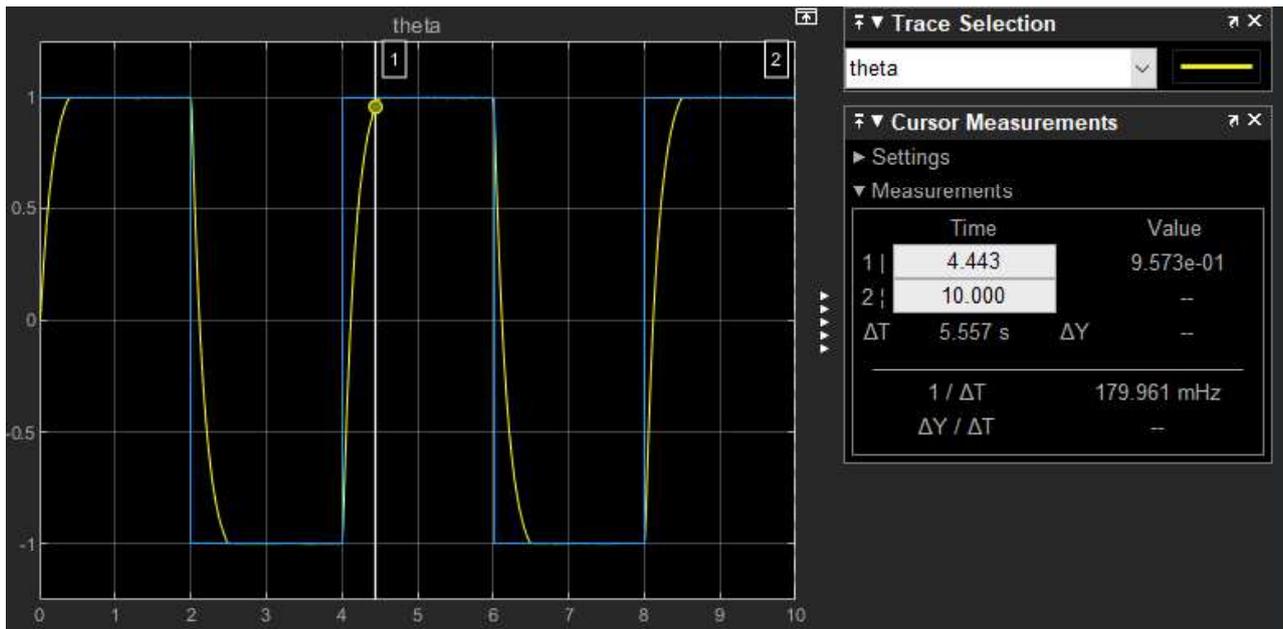


Figura 15: Respuesta final obtenida

Como se muestra, la red neuronal ha realizado un control excelente para el sistema. La respuesta carece de sobreoscilación y el tiempo de establecimiento es de 443 milisegundos, algo mucho más profesional de los que se propuso en el apartado de objetivos. Por supuesto no existe error en régimen permanente y el sistema se mantiene estable en todo momento.

Cabe destacar que el control que realiza la red neuronal resulta extraño ya que la respuesta carece de la curva de aproximación característica en las respuestas de control. Una vez que la respuesta llega a 1 y -1, donde el error que recibe al red es cero completamente, la red satura la respuesta estabilizándose casi instantáneamente a su valor final. Prácticamente podría sospecharse de un sistema manipulado donde no se ha conseguido establecer correctamente el régimen permanente y donde se habrían usado los bloques de saturación entre 1 y -1 para falsificar la respuesta. Por ello, junto con esta memoria se adjunta el archivo de Simulink rct\_helico\_project\_NN.slx para que se compruebe que la respuesta es completamente real y que no ha sufrido ninguna manipulación ni falsificación.

Para comprobar la respuesta frente a otro tipo de estímulos se ha incluido una entrada variable y una entrada senoidal:

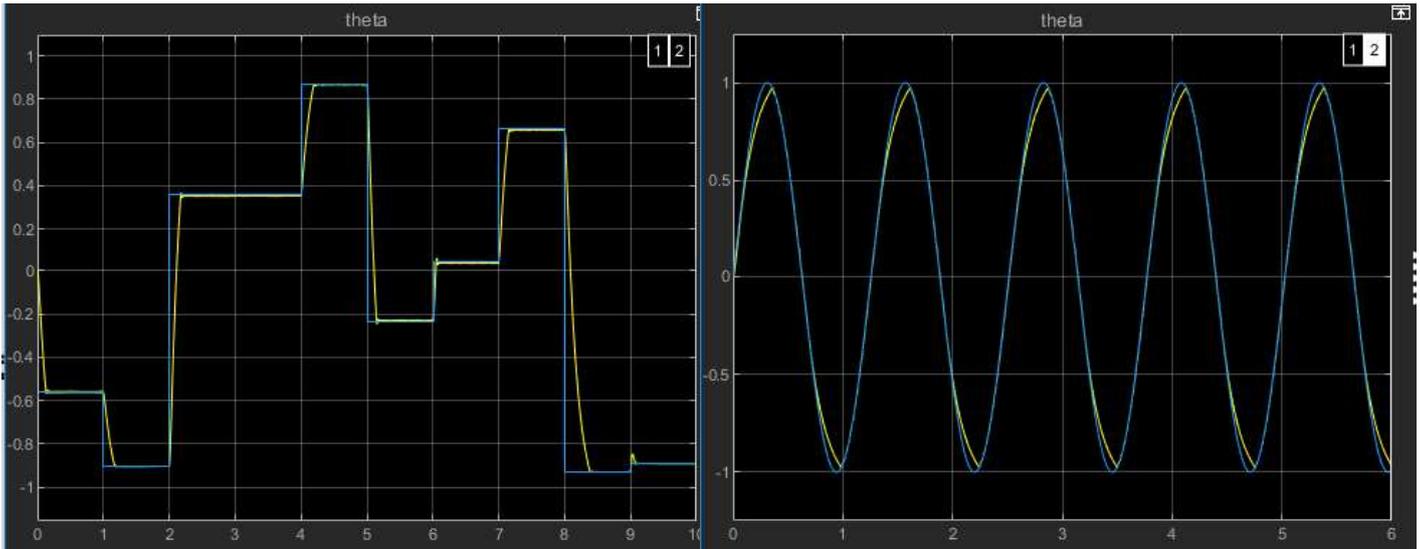


Figura 16: Respuesta a entrada variable y entrada senoidal

A continuación, se muestra la respectiva configuración para poder replicar el entrenamiento:

### Plant Identification - NARMA-L2

Network Architecture

Size of Hidden Layer: <input type="text" value="15"/>	No. Delayed Plant Inputs: <input type="text" value="3"/>
Sampling Interval (sec): <input type="text" value="0.001"/>	No. Delayed Plant Outputs: <input type="text" value="3"/>

Normalize Training Data

Training Data

Training Samples: <input type="text" value="3500"/>	<input checked="" type="checkbox"/> Limit Output Data
Maximum Plant Input: <input type="text" value="20"/>	Maximum Plant Output: <input type="text" value="Inf"/>
Minimum Plant Input: <input type="text" value="-20"/>	Minimum Plant Output: <input type="text" value="-Inf"/>
Maximum Interval Value (sec): <input type="text" value="0.1"/>	Simulink Plant Model: <input type="button" value="Browse"/>
Minimum Interval Value (sec): <input type="text" value="0.01"/>	<input type="text" value="rct_helico_project_learning1"/>

Training Parameters

Training Epochs: <input type="text" value="10000"/>	Training Function: <input type="text" value="trainlm"/>
<input checked="" type="checkbox"/> Use Current Weights	<input checked="" type="checkbox"/> Use Validation Data
	<input checked="" type="checkbox"/> Use Testing Data

Figura 17: Configuración final

Esta ha sido la mejor configuración que se ha obtenido para el controlador y por lo tanto la mejor respuesta mostrada, sin embargo, han sido necesarias numerosas pruebas hasta llegar a esta configuración. Por consiguiente, en el próximo apartado se expondrá el proceso que se ha seguido y todas las pruebas falladas hasta llegar a la configuración mostrada.

## 8. EVOLUCIÓN DEL MÉTODO EXPUESTO

### [Prueba de control 1](#)

La primera configuración que se probó fue la descrita donde el rango de identificación variaba entre -1 y 1.

**Plant Identification - NARMA-L2**

**Network Architecture**

Size of Hidden Layer: 10  
No. Delayed Plant Inputs: 3  
Sampling Interval (sec): 0.01  
No. Delayed Plant Outputs: 3  
 Normalize Training Data

**Training Data**

Training Samples: 3000  
Maximum Plant Input: 1  
Minimum Plant Input: -1  
Maximum Interval Value (sec): 1  
Minimum Interval Value (sec): 0.1  
 Limit Output Data  
Maximum Plant Output: Inf  
Minimum Plant Output: -Inf  
Simulink Plant Model: rct\_helico\_project\_learning1  
Generate Training Data | Import Data | Export Data

**Training Parameters**

Training Epochs: 10000  
Training Function: trainlm  
 Use Current Weights  
 Use Validation Data  
 Use Testing Data  
Train Network | OK | Cancel | Apply

Figura 18: Configuración 1

Sin embargo, la respuesta del sistema de estacionaba con una atenuación de 18 aproximadamente.

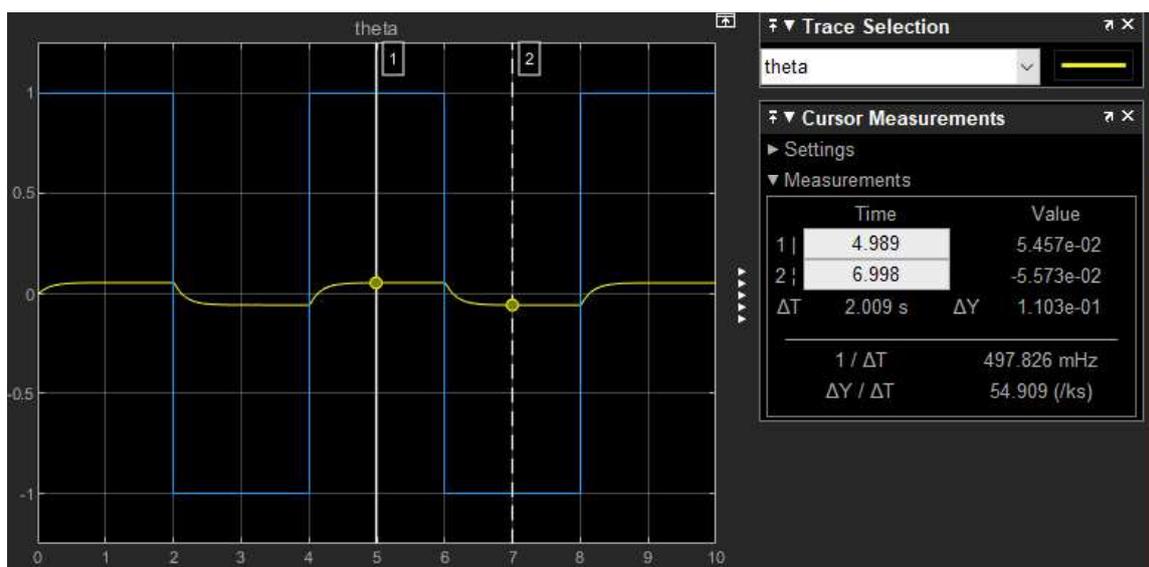


Figura 19: Respuesta 1

## Prueba de control 2

Por ello, se ampliaron los límites de identificación del sistema como se muestra en la siguiente configuración. También se aumentaron a 5 el número de entradas y salidas retardadas para comprobar si con un grupo mayor de datos por iteración se llegaría al control adecuado.

**Plant Identification - NARMA-L2**

**Network Architecture**

Size of Hidden Layer: 10  
Sampling Interval (sec): 0.01  
No. Delayed Plant Inputs: 5  
No. Delayed Plant Outputs: 5  
 Normalize Training Data

**Training Data**

Training Samples: 2000  
Maximum Plant Input: 40  
Minimum Plant Input: -20  
Maximum Interval Value (sec): 2  
Minimum Interval Value (sec): 0.1  
 Limit Output Data  
Maximum Plant Output: Inf  
Minimum Plant Output: -Inf  
Simulink Plant Model: Browse  
rct\_helico\_project\_learning1

**Training Parameters**

Training Epochs: 10000  
Training Function: trainlm  
 Use Current Weights  
 Use Validation Data  
 Use Testing Data

Buttons: Generate Training Data, Import Data, Export Data, Train Network, OK, Cancel, Apply

Generate or import data before training the neural network plant.

Figura 20: Configuración 2

Esta configuración tampoco resultó efectiva ya que creaba una asimetría entre las entradas positiva y negativa, a la vez que una peligrosa y rápida oscilación antes del establecimiento.



Figura 21: Respuesta 2

### Prueba de control 3

Para la siguiente prueba se redujeron los límites de los pulsos de identificación. Las entradas y salidas retardadas se ajustaron a 3 y 3 para probar nuevas respuestas.

**Plant Identification - NARMA-L2**

**Network Architecture**

Size of Hidden Layer: 10  
Sampling Interval (sec): 0.01  
No. Delayed Plant Inputs: 3  
No. Delayed Plant Outputs: 3  
 Normalize Training Data

**Training Data**

Training Samples: 4000  
Maximum Plant Input: 30  
Minimum Plant Input: -20  
Maximum Interval Value (sec): 1  
Minimum Interval Value (sec): 0.1  
 Limit Output Data  
Maximum Plant Output: Inf  
Minimum Plant Output: -Inf  
Simulink Plant Model: Browse  
rct\_helico\_project\_learning1

**Training Parameters**

Training Epochs: 10000  
Training Function: trainlm  
 Use Current Weights  
 Use Validation Data  
 Use Testing Data

Figura 22: Configuración 4

Con este modelo se eliminaron las vibraciones y se creó una respuesta simétrica. Sin embargo, la sobreoscilación se considera excesiva por lo que se intentará obtener una respuesta mucho más rigurosa y profesional.



Figura 23: Respuesta 4

## Prueba de control 4

Dado que con todos los intentos anteriores no se ha conseguido una respuesta exitosa se procede a aumentar el número de neuronas de la capa oculta. Se añadirán tres neuronas más para comprobar los resultados.

**Plant Identification - NARMA-L2**

**Network Architecture**

Size of Hidden Layer: 12      No. Delayed Plant Inputs: 3  
Sampling Interval (sec): 0.01      No. Delayed Plant Outputs: 3

Normalize Training Data

**Training Data**

Training Samples: 2000       Limit Output Data  
Maximum Plant Input: 18      Maximum Plant Output: Inf  
Minimum Plant Input: -18      Minimum Plant Output: -Inf  
Maximum Interval Value (sec): 1      Simulink Plant Model: Browse  
Minimum Interval Value (sec): 0.1      rct\_helico\_project\_learning

Generate Training Data    Import Data    Export Data

**Training Parameters**

Training Epochs: 10000      Training Function: trainlm  
 Use Current Weights     Use Validation Data     Use Testing Data

Train Network    OK    Cancel    Apply

Figura 24: Configuración 5

La red Narma-L2 es incapaz de ajustar el error en régimen permanente de forma adecuada. Se necesitan más datos para poder realizar un control óptimo.

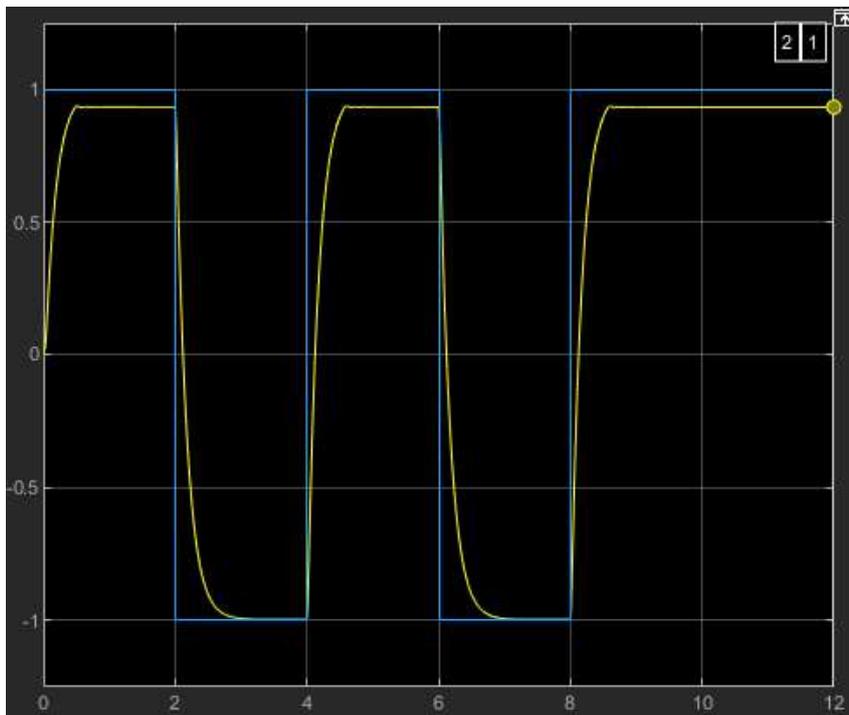


Figura 25: Respuesta 5

## Prueba de control final

Para crear una mejor identificación de la planta se ha aumentado el muestreo a 0.001 segundos. Los pulsos de identificación se reducen entre 0.1 y 0.01 para comprobar si la red necesita una identificación de la planta mucho más precisa. Para que el ajuste sea mejor se ha aumentado asimismo el número de neuronas de la capa oculta a 15.

Se mantienen las entradas y salidas retardadas a 3 y 3 respectivamente. Así es como finalmente se llega a la configuración exitosa que fue mostrada en el apartado 7 de 'Evaluación de resultados'.

## 9. CONCLUSIONES

---

Como se ha demostrado en este proyecto, las redes neuronales y en concreto el bloque Narma-L2, representan nuevos sistemas de control. Estos nuevos controladores implementan estrategias mucho más complejas que los métodos clásicos de control como el regulador Proporcional Integral Derivativo. Finalmente, se exponen las conclusiones que se han desarrollado a lo largo de todo el proyecto:

- Las redes neuronales son poderosos métodos para controlar sistemas. Como se ha podido comprobar, el bloque Narma-L2 es capaz de otorgar un rendimiento extraordinario para controlar sistemas no lineales.
- Sin embargo, el éxito de su eficacia reside parcialmente en su complejidad. A lo largo de las pruebas de control se ha mostrado que el resultado idóneo no se consigue a la primera, sino que es necesario entender y ajustar cuidadosamente los parámetros que el bloque Narma-L2 precisa.
- Esto es, a su vez, una desventaja, ya que al actuar como una "caja negra" no se mantiene un control directo sobre lo que está ocurriendo dentro de la red. Al contrario de un control PID, donde se puede controlar cada ganancia de forma relativamente fácil, la red neuronal es un campo de estudio infinitamente más extenso. Un PID puede ser diseñado de forma exitosa en poco tiempo, mientras que, diseñar una red neuronal completa con su respectivo aprendizaje requiere de un manejo exhaustivo en técnicas de programación.