

Capítulo 1

Introducción

En esta memoria se describe el estudio realizado y el marco de trabajo propuesto para el modelado de una familia de sistemas dinámicos utilizando redes neuronales modulares.

La disciplina que ha motivado este trabajo es el control de sistemas dinámicos y en este ámbito hay dos elementos que estarán presentes, a lo largo de todo el estudio, de forma implícita. Se trata de la familia de sistemas que se desea modelar y del marco de modelado, que caracteriza la forma en que se ha realizado el trabajo. Seguidamente se describen más detalladamente estos dos aspectos.

1.1 Los sistemas que se utilizan como soporte del estudio

La familia de sistemas que se utiliza como soporte de este trabajo es la formada por el conjunto de sistemas dinámicos susceptibles de ser controlados. Dentro de este gran conjunto, que incluye sistemas lineales, caóticos, variables en el tiempo, etc., se ha considerado, por su riqueza y representatividad, el grupo de sistemas de una entrada y una salida que pueden modelarse siguiendo el esquema de la figura 1.1.




Fig. 1.1: Esquema de la clase de sistemas que se modelan

En la figura 1.1 se representa un sistema en lazo abierto formado por la combinación en serie de bloques basados en un sistema lineal (bloque L) modificado a su entrada y a su salida por

características no lineales (bloques N). Los bloques N corresponden a no-linealidades de las que, comúnmente, se llaman duras (*hard nonlinearities*). En esta categoría se encuentran funciones estáticas como la saturación, la zona muerta, la característica de dos o más estados, etc. y también hay comportamientos, como el juego de los engranajes, la histéresis de dos estados, etc. que se caracterizan a través de funciones dinámicas.

La gama de sistemas que se puede representar mediante un modelo como el propuesto es muy amplia. En general, la mayoría de los sistemas dinámicos cuyo comportamiento sea básicamente lineal pero que, debido a la introducción de sensores y actuadores, presenten no-linealidades, podrán modelarse siguiendo el esquema de la figura 1.1. Ejemplos de este tipo de sistemas son una cámara con un calentador de tipo todo-nada en la que se mide la temperatura y un motor de corriente continua alimentado por un amplificador. Además, también hay sistemas, en especial mecánicos y electromecánicos, que intrínsecamente, incorporan no-linealidades duras, como las zonas muertas que se dan en las servoválvulas o los juegos que aparecen en la mayoría de los engranajes.

Los sistemas que contienen no-linealidades analíticas (funciones trigonométricas, polinómicas, exponenciales, etc.) de sus entradas o de alguna de sus señales internas quedarán, en general, excluidos del conjunto que se trata en este estudio. La principal razón de esta limitación es la existencia de algunas técnicas para su modelado y control. En efecto, una parte de los sistemas que contienen no-linealidades analíticas son abordables a través de herramientas matemáticas más o menos modernas. Hay que tener en cuenta que las funciones analíticas gozan, en general, de propiedades (continuidad, derivabilidad, etc.) que las hacen más manejables que las no analíticas a la hora de extraer características sobre su comportamiento dentro de la dinámica de un sistema. Esto ha llevado a la aparición de un número apreciable de técnicas de análisis y control, por ejemplo: análisis de estabilidad de Lyapunov o diseño de controladores a través de linealización por realimentación.

1.2 El proceso empírico de creación de modelos

De acuerdo con el proceso empírico de creación de modelos descrito en [Pear-97] una condición necesaria para que $\mathbf{M}$ sea un buen modelo del proceso $\mathbf{P}$, para un conjunto preestablecido de secuencias de entrada $\mathbf{S}$, es que:

$$\mathbf{M}(u) \cong \mathbf{P}(u), \forall u \in \mathbf{S}$$

donde $\mathbf{M}(u)$ y $\mathbf{P}(u)$ representan las respuestas del modelo y del proceso ante una determinada secuencia de entrada, u .

En esta condición se dan varios elementos que la hacen altamente flexible y son: la interpretación del símbolo $\cong$, el conjunto de entradas $\mathbf{S}$ y la clase de modelos, $\mathbf{C}$, de la que se busca el mejor de ellos, $\mathbf{M}$.

Es fundamental, en primer lugar, aclarar el significado que se adopta del símbolo $\cong$. ¿Qué quiere decir que un modelo *aproxima* correctamente la salida de un sistema? Esta pregunta nos lleva a cuantificar, de alguna manera, la diferencia entre las respuestas del modelo y las del proceso, el *error*. Existen múltiples medidas del error y cada una de ellas puede tener una justificación válida en diferentes ámbitos. Las medidas clásicas en control de procesos son la suma cuadrática de errores (ISE), la suma absoluta de errores (IAE) y las sumas cuadráticas y absolutas de los errores multiplicados por el tiempo (ITSE e ITAE). Sin embargo, también podría ser interesante tener en cuenta la capacidad aproximativa del modelo respecto a las derivadas de la salida del proceso o la complejidad computacional (número de parámetros, coste computacional de las operaciones) del modelo.

En este trabajo el error se mide con dos tipos de criterios. En los resultados formales se utiliza la norma infinita, que permite acotar el error máximo de una aproximación. Por otro lado, en los resultados experimentales se utiliza la suma cuadrática de los errores.

Esta medida del error se caracteriza por penalizar más los errores de mayor magnitud y por no tener en cuenta el instante en que se han producido. Además, puesto que es una función derivable, permite la optimización de los parámetros del modelo mediante algoritmos de descenso del gradiente. Esta medida del error es útil cuando se comparan modelos de complejidad similar, o lo que es lo mismo, igual número de parámetros. Pero en este trabajo se crearán modelos de complejidad dispar, por lo que también se utilizan criterios estándar de medidas del error que ponderan la complejidad del modelo, como el *Akaike's Information theoretic Criterion* (AIC).

Así como la selección del criterio de error puede, en general, realizarse a priori, es bastante más comprometido seleccionar el conjunto de zonas de trabajo o señales de entrada, $\mathbf{S}$, para los que el modelo $\mathbf{M}$ será válido. Los sistemas no lineales tienen, entre otras, la característica de presentar comportamientos cualitativamente diferentes según el régimen de operación en que se encuentren. Por ejemplo, un sistema de primer orden en lazo cerrado cuya entrada está saturada puede oscilar indefinidamente o tender hacia un valor de salida constante dependiendo de la amplitud de una entrada tipo escalón. No existe una forma sistemática de saber cuántos de estos regímenes de operación hay y, sobretodo, cómo llegar a ellos (qué entradas llevarán al proceso a estos estados).

En este trabajo se utilizarán métodos ya consolidados, como los descritos en [Codi-96] y [Esco-97]. El conjunto de señales de entrada que se utilizará es el formado por secuencias pseudoaleatorias multinivel o por secuencias binarias de longitud máxima, que suele llevar al sistema a gran parte de sus estados alcanzables. Este tipo de señales, por ser persistentemente excitadoras, permite una caracterización óptima de los sistemas lineales, pero esto no es así, necesariamente, en los sistemas no lineales. Para minimizar este problema se divide el conjunto S en tres subconjuntos, S_I , S_T , y S_V (señales de identificación, de test y de validación) de forma que la evaluación de un modelo se hará con las señales de S_V , que nunca fueron utilizadas en el proceso de creación del modelo.

Finalmente queda por presentar la clase de modelos, C , en que se basará este trabajo. Tal y como permite inferir el título de esta memoria, la clase de modelos que se estudiará es la de las redes neuronales modulares, que será extensamente caracterizada y justificada en el capítulo 2.

1.3 Esquema de la memoria

La memoria de este trabajo está organizada en un capítulo de introducción, cuatro capítulos centrales y un último capítulo de conclusiones. Además, también incluye dos apéndices de resultados.

El segundo capítulo justifica el uso de las redes neuronales en la identificación y control de procesos y presenta una arquitectura neuronal nueva, que denominamos *módulo neuronal*. En él se define el concepto, se dan pautas para su creación y se describe una librería de no-linealidades típicas modeladas por este tipo de redes neuronales.

La mayor parte de los resultados teóricos de este trabajo se formalizan en el tercer capítulo, en que se caracteriza el conjunto de sistemas dinámicos que se puede aproximar mediante redes de módulos neuronales y se calculan las cotas del error máximo que estas redes pueden cometer al aproximar un sistema de dicho conjunto.

En el cuarto capítulo se introducen las técnicas evolutivas como método de optimización en el diseño de redes neuronales. Se describe una herramienta diseñada a propósito para el modelado de sistemas no lineales. Esta herramienta utiliza los módulos neuronales como estructura básica para crear redes modulares mediante técnicas de optimización evolutiva. En este capítulo se presenta también el diseño un algoritmo de aprendizaje, genérico para redes neuronales modulares y más eficiente que los algoritmos clásicos con este tipo de arquitecturas.

El quinto capítulo describe una metodología para el uso eficiente de la herramienta indicada anteriormente. Además, presenta tres ejemplos de aplicación en los que se utiliza esta metodología. Los resultados que se obtienen en estos casos permiten validar las estructuras aportadas en la tesis.

Finalmente el último capítulo recoge las conclusiones, aportaciones, valoraciones y líneas de trabajo abiertas en este estudio.