

# Capítulo 6:

## Conclusiones y trabajo futuro

### 6.1. Conclusiones

#### 6.1.1. Revisión y conclusiones de carácter general

Se ha desarrollado un modelo matemático del motor, el cual ha sido validado con diferentes mediciones obtenidas experimentalmente en las instalaciones de ensayo. La comparación de los resultados procedentes de la simulación y de los ensayos, aplicando seis secuencias distintas de las entradas (ángulo de mariposa  $\alpha$ , tiempo de inyección  $ti$ ), muestra una buena aproximación en el cálculo de las variables que intervienen en el proceso de formación de la mezcla (caudal de combustible  $\dot{m}_f$ , caudal de aire  $\dot{m}_a$ , presión de admisión  $P_{adm}$ , relación aire combustible  $\lambda$ ), e incluso en la generación de par y la dinámica del coche (cálculo del régimen del motor), a pesar de su simplicidad.

La bibliografía consultada para la realización del modelo del motor ofrece algoritmos normalmente incompletos, donde no se menciona el procedimiento de ajuste de los parámetros. Dado que estos modelos se utilizan para su aplicación directa en control, y no para reemplazar al motor en la simulación de estrategias de control, ha sido necesaria una síntesis y revisión de todos los trabajos hallados.

Con el modelo desarrollado se han simulado algoritmos de control de  $\lambda$ , consistentes en un bloque en lazo abierto (*feedforward*), y uno en lazo cerrado (*feedback*).

El controlador *feedforward*, utilizado con todos los controladores *feedback*, se basa en un mapa estático del tipo  $\alpha/n$ , sin incluir corrección dinámica alguna. La razón es que, aunque ha sido el objeto de estudio y mejora de la mayoría de los autores, no lo es de esta tesis. Solamente se añade un término de corrección de tendencia, lo que reduce ligeramente las desviaciones de  $\lambda$  respecto al valor de consigna.

El controlador *feedback*, sobre el que se ha centrado esta tesis, comienza siendo un PI con la señal de realimentación procedente de la sonda EGO, lo cual permite analizar la capacidad de control de un sistema comercial, basado en este tipo de sonda. Posteriormente, se sustituye la sonda por una UEGO, y al controlador se le añade un término D, apreciándose una mejora importante. Por último, se cierra el lazo de control no desde la sonda, sino desde el controlador avanzado, formado por la red neuronal, junto con un PID.

Con la utilización de una sonda UEGO se logra un mejor comportamiento del sistema en lazo cerrado y una mayor robustez, tanto a desviaciones lineales en la sintonía del término *feedforward*, como a la presencia de ruido en la acción de control. Además, lo que es más importante, puede aplicarse como consigna una señal senoidal, de amplitud y frecuencia tales que optimicen la capacidad de almacenamiento de oxígeno, característica del catalizador utilizado.

A continuación, se ha definido un observador basado en una red neuronal, que permite de esta forma aprender la dinámica del motor, pero sin los retardos puros. Esta idea no ha sido utilizada por ningún autor de los consultados en la bibliografía, y los resultados permiten constatar que el procedimiento funciona correctamente, obteniéndose resultados equiparables a los logrados por algunos autores, a base de desarrollar un controlador *feedforward* muy complejo. Como núcleo del observador se ha optimizado una red neuronal *feedforward* en primer lugar, y tres variantes de red recurrente, mediante entrenamiento inicial *off-line* y posteriormente *on-line*. Los casos de aplicaciones de redes neuronales, hallados en la bibliografía consultada, están orientados sobre todo a redes *feedforward*, y aplicaciones con plantas muy sencillas y sin retardos puros. Apenas se han encontrado aplicaciones de redes neuronales recurrentes a problemas análogos al planteado en esta tesis.

Las secuencias utilizadas para la identificación *off-line*, correspondientes a las tres entradas  $\alpha$ ,  $n$  y  $ti$ , se han elegido considerando las limitaciones dinámicas de cada una de ellas. Se ha comprobado que la mejor identificación se logra si a la señal de  $ti$  se le suma un término pseudoaleatorio binario.

La identificación mediante una red *feedforward* es muy precisa si esta puede realizarse en serie-paralelo, es decir, utilizando las salidas reales del motor como entradas de la red. Dado que esto no es posible en realidad, puesto que la salida del motor siempre va retardada respecto a la predicción de la red, sólo pueden utilizarse las propias salidas de la red como entradas. El error de identificación así obtenido es 10 veces mayor, lo que ha llevado a desarrollar una red recurrente para constituir el observador.

La red recurrente que se ha tomado como punto de partida es la red de Elman. Al disponer de memorias de contexto, que guardan el estado de las neuronas correspondientes a una de las capas ocultas, no es necesario aplicar entradas y salidas en

instantes anteriores como entradas a la red. Dado que la red de Elman sólo memoriza un estado, y como se ha visto al dimensionar la red *feedforward* se requiere un mínimo de dos estados, es necesario recurrir a la red de Elman modificada. Esta memoriza, además, el valor anterior de las neuronas de contexto. De esta forma, se obtiene un desarrollo recursivo, que resulta en una memoria con ponderación exponencialmente decreciente de los estados anteriores. Se ha optimizado una red con memoria de la primera capa oculta, y otra con las neuronas de contexto aplicadas a la segunda capa. La identificación *off-line* es mejor en el primer tipo de red que en el segundo, y peor que con una red de tipo *feedforward* cuando se aplica la secuencia de entrenamiento, aunque mucho mejor si la secuencia es otra diferente. No obstante, los resultados no son suficientemente satisfactorios. Por ese motivo se ha desarrollado una variante del algoritmo de entrenamiento, que permite modificar los factores de memoria como si fueran unos pesos más. El resultado es una mejora sustancial, a la vez que se comprueba que estos factores de memoria evolucionan asintóticamente hasta un valor determinado, diferente para cada uno de ellos, a partir del cual no varían.

El análisis de la evolución de los factores de memoria durante el entrenamiento de las redes anteriores ha llevado a crear un nuevo tipo de red recurrente, la denominada de tipo 3. Esta consiste en aplicar las neuronas de contexto a la primera capa oculta, pero dividiendo tanto estas como la primera capa en tres grupos, asociado cada uno de ellos a una entrada de la red. Al aplicar a esta red el algoritmo de entrenamiento de los pesos y los factores de memoria, se aprecia cómo los factores correspondientes a la entrada  $n$  apenas varían; los relacionados con  $\alpha$  toman valores muy bajos, mientras que los que tienen  $ti$  como entrada varían de forma muy diferente. Con ello, y a la vista de los resultados obtenidos, se confirma que este tipo de red permite identificar mucho mejor plantas con varias entradas y con una dinámica asociada a cada una de ellas muy diferente. Se comprueba sobre todo la gran capacidad de generalización, cuando se aplica una secuencia de entrada desconocida para la red.

Finalmente, se cierra el lazo de control desde la salida del observador, efectuando un entrenamiento *on-line* de la red neuronal. De nuevo, los mejores resultados, entendidos como el menor error de seguimiento de la consigna, sea esta constante o variable, se obtienen con la red de tipo 3, aportación principal de esta tesis. Se comprueba la estabilidad y la robustez del sistema en lazo cerrado, frente a distintas clases de perturbación.

La solución obtenida se puede aplicar fácilmente a cualquier tipo de controlador comercial, añadiendo el software correspondiente, independientemente del sistema considerado y sin requerir sensores o actuadores adicionales. Las ventajas frente a otros métodos, incluso más complejos, son manifiestas cuando los retardos puros son importantes, y los parámetros de la planta son variables en el tiempo.

### 6.1.2. Conclusiones particulares

Se ha observado que el modelo de Aquino, para la representación de la evolución del combustible en el colector de admisión, funciona con un grado de precisión

aceptable para la resolución del problema de control propuesto, aún suponiendo que los parámetros  $\tau_{fl}$  y  $X$  son constantes. No es necesario, por tanto, considerar la transferencia de calor en el colector de admisión, como afirman algunos autores, ya que estos dos parámetros comprenden esos fenómenos.

El modelo de la válvula de mariposa es tratado por todos casi todos los autores como una aplicación de la ecuación de Saint Venant, simplificando el factor de sección a un desarrollo de Fourier con uno o dos armónicos. Tampoco se ha hallado información sobre el cálculo del coeficiente de descarga, que muchos autores consideran constante. Se ha podido comprobar que en un motor real, estos dos factores son bastante más complejos. El producto de ambos, determinado de forma experimental, puede aproximarse por un polinomio de quinto grado. También se confirma la hipótesis de Hendricks, de modo que para ángulos pequeños y cargas altas existe una saturación del caudal de aire, que es función únicamente del régimen de giro.

El modelo de llenado y vaciado, con ayuda de los submodelos de la válvula de mariposa y del rendimiento volumétrico, logra simular la presión de admisión, aún en el caso de tenerse un colector de longitud variable, siempre y cuando el volumen interior sea constante.

El rendimiento volumétrico puede simplificarse a una expresión, en la que sólo interviene la presión de admisión y el régimen de giro, según el modelo propuesto por Hendricks. La dependencia de otras variables, como por ejemplo  $\lambda$  o las propiedades de los gases de escape, incluidas en el modelo de Servati, puede despreciarse sin pérdida importante de precisión en el resultado. En cambio, hay que considerar una función cuadrática de la presión de admisión, en lugar de lineal.

El retardo de transporte de los gases desde la válvula de escape, hasta la posición de la sonda lambda, puede estimarse bien sea experimentalmente, bien por cálculo teórico, conociendo las variables termodinámicas de la mezcla en la admisión y los gases en el escape. La dependencia con el régimen de giro es de tipo  $1/x$ , a lo que hay que sumar una función exponencial decreciente del ángulo de mariposa, representativa hasta aproximadamente  $20^\circ$ . En cualquier caso, coinciden los resultados obtenidos por los dos procedimientos, teórico y experimental.

No es necesario un modelo de la combustión complejo para la determinación del par generado. Si se supone que el ángulo de encendido es siempre óptimo, basta con determinar el valor empírico del rendimiento térmico, según las ecuaciones propuestas por Hendricks. En este caso, se puede simplificar la dependencia conjunta de  $\lambda$  y  $n$  en la expresión del rendimiento térmico, a solamente  $\lambda$ .

La introducción del término de corrección de tendencia en el controlador *feedforward*, según visto en el apartado 4.5, permite una mejora del 16% en el control, sin complicar el modelo y sin necesidad de ajustes adicionales, ya que una vez determinada la frecuencia de filtrado y la ganancia, estos valores no deben variar.

La aplicación de un control PI en lazo cerrado mediante EGO, ha permitido determinar que la desviación de  $\lambda$  respecto al punto estequiométrico es función lineal de la amplitud del tiempo de inyección, aumentando conforme el ángulo de mariposa es

menor. La frecuencia de oscilación aumenta con el ángulo, y se reduce al aumentar la amplitud del tiempo de inyección, hasta un valor en el cual se mantiene constante e independiente del ángulo. Ambos parámetros, amplitud y frecuencia, son función del régimen de giro del motor. Se ha visto que los valores para los cuales el error de control es mínimo corresponden a una amplitud de oscilación de  $\lambda$  del 5%, aplicando un salto brusco debido a la acción proporcional equivalente al 80% de la amplitud total del tiempo de inyección, mientras que la aportación de la acción integral ha de ser de tan sólo el 20%, lo imprescindible para eliminar el error estacionario.

Al sustituir la sonda EGO por una UEGO, el error de control se reduce en un 7% con el mismo controlador PI nuevamente sintonizado, y hasta un 20% si se añade un término derivativo, tal como se muestra en el apartado 4.4.

Los métodos de sintonía clásicos utilizados, tanto en lazo abierto como en lazo cerrado, producen resultados similares, con la ventaja de que la sintonía en lazo cerrado puede hacerse *on-line*, cuando el funcionamiento del motor sea en régimen estacionario.

Se ha efectuado un análisis de un modelo de entrada-salida lineal (ARX), que si bien ha proporcionado unos resultados microscópicos de identificación malos, como era de esperar dada la complejidad de la planta, ha permitido la determinación de las características macroscópicas más importantes del motor como sistema dinámico, y de este modo el predimensionamiento de las redes neuronales. El número óptimo de entradas anteriores para el modelo de entrada-salida es de tres, mientras que con dos salidas anteriores es suficiente. Se ha visto que estos valores proporcionan los mejores resultados en una red neuronal *feedforward*. El retardo aparente con el que se obtiene la mejor identificación coincide con el determinado a la hora de ajustar el modelo, aunque cuando se ha cerrado el lazo de control con la red recurrente de tipo 3, se ha visto que el error se reduce si el retardo aparente se incrementa en un 20% respecto al retardo puro de la planta. Este retardo aparente adicional comprendería parte de la constante de tiempo, introducida por la UEGO.

En lo que se refiere a la estructura de las redes neuronales, se han utilizado dos capas ocultas para asegurar una mejor identificación, según las recomendaciones halladas en la bibliografía. También se ha comprobado que es mejor usar tangentes hiperbólicas como funciones de activación en las dos capas, en lugar de funciones lineales, lo que se explica por la alta no linealidad del motor. Un total de 12 y 6 neuronas respectivamente en cada una de las capas es suficiente, ya que un número mayor no consigue reducir el error de identificación, y en cambio llega a empeorar la generalización de la red, al favorecer la aparición de mínimos locales.

El algoritmo clásico de retropropagación se ha modificado para la adaptación del factor de aprendizaje, y para el entrenamiento de los pesos de las neuronas de contexto, en las redes recurrentes. A pesar de ello, no ha podido evitarse algún caso de inestabilidad en el aprendizaje *off-line*, que ha debido resolverse variando los valores iniciales de los pesos.

El error de identificación con las redes recurrentes es mayor que el obtenido con la red *feedforward*, pero tienen una mejor capacidad de generalización. No obstante, las redes recurrentes convergen muy lentamente en el proceso de entrenamiento, en

comparación con las *feedforward*.

Se ha demostrado que la red recurrente de neuronas de contexto agrupadas por entradas, desarrollada en esta tesis, consigue identificar un modelo bastante complejo, como es el caso del motor, mejor que las estructuras simples y además generaliza mucho mejor, lo cual es fundamental en la resolución del problema planteado. En cambio, tanto las redes *feedforward* como las redes recurrentes con una sola región de contexto tienen un comportamiento pobre cuando se trata de problemas con plantas complejas, y donde no es posible aplicar el esquema serie-paralelo.

No puede utilizarse entrenamiento *on-line* de los factores de memoria, puesto que el sistema se vuelve inestable. Por ello, se toman como fijos los valores obtenidos tras el entrenamiento *off-line*. Se observa que el mejor comportamiento durante el entrenamiento *on-line* se produce cuando se presentan entre 1 y 4 muestras, dependiendo del tipo de red, mientras que el entrenamiento *off-line* se realizaba con todo el conjunto de muestras simultáneamente. Esto se debe a que el entrenamiento *on-line* tiene como principal finalidad compensar el error estacionario en la identificación del motor sin retardos, mientras que la dinámica se ha aprendido durante el entrenamiento *off-line*. Dado que el entrenamiento se produce con retardo respecto a la predicción, conviene aprender únicamente las muestras más recientes.

A la hora de sintonizar el controlador PID, se ha visto que el término derivativo tiene muy poco efecto, mientras que la estabilidad en lazo cerrado es muy sensible a la acción proporcional cuando la ganancia es alta, puesto que el control puede interferir con el proceso de aprendizaje de la red neuronal. En este sentido, se ha comprobado que es preferible disminuir ligeramente la ganancia y aumentar el factor de aprendizaje. Se ha comprobado asimismo que un período de muestreo de 2 ms es suficiente, ya que un tiempo menor no mejora la respuesta del sistema.

La aplicación del observador, basado en la red neuronal desarrollada, para el control de  $\lambda$  en lazo cerrado, reduce aproximadamente en 10 veces el error respecto al esquema convencional, cuando se aplica una consigna constante o senoidal de 1 Hz, y en 4 veces si la frecuencia de la señal de consigna es de 4 Hz. Se logra al mismo tiempo un sistema muy robusto al ruido en la señal de  $t_i$ , y a los defectos de sintonía del controlador *feedforward*. El error de control se duplica con una desviación del 10% en el retardo puro originado en el motor, y del 20% en el retardo aparente que se aplica al observador.

Un problema importante ligado al estado de la tecnología actual es la gran capacidad de cálculo requerida. Los entrenamientos y las simulaciones se han desarrollado en un PC en el lenguaje MatLab®, lo cual es muy práctico en la fase de desarrollo del software, pero en el caso de realizar un montaje real, debería recurrirse a procesadores más apropiados (estructuras paralelas) y lenguajes de bajo nivel. Como referencia, un entrenamiento de 500 épocas con una red recurrente de tipo 3 dura unas 4,5 horas, y la simulación en lazo cerrado con el modelo del motor y entrenamiento *on-line* de la red tarda 45 minutos en completarse, con una secuencia de entrada de 40 segundos reales.

## 6.2. Trabajo futuro

En este apartado se engloba una serie de propuestas de continuación o mejora del trabajo iniciado con esta tesis.

Se propone en primer lugar la mejora del modelo del motor, en los apartados referentes a combustible, combustión y escape de los gases quemados. Dentro del bloque de combustible, se puede estudiar más a fondo la dependencia de los parámetros  $\tau_{fl}$  y  $X$  con el punto de funcionamiento del motor, y con la temperatura del refrigerante; esto permitiría la generalización del modelo al caso de motor frío, y la simulación más real del ensayo de emisiones. El desarrollo del bloque de combustión, debería permitir la inclusión de otros parámetros, como avance de encendido y modelo del frente de llama, que permitan calcular con mayor precisión el par generado y la evolución de este dentro del ciclo. Por último, se puede completar el modelo de cálculo del retardo de transporte de los gases de escape, considerando no solamente un tiempo función del punto de funcionamiento y determinadas variables termodinámicas, sino el proceso físico-químico de difusión de los gases expulsados en los ya existentes en el escape, para obtener un modelo dinámico.

Se propone el ajuste del modelo desarrollado con un motor de diferente cilindrada, para comprobar que los submodelos desarrollados son generalizables, o incluso la aplicación a otro tipo de motores de gasolina, como puede ser el caso de dos tiempos o con inyección directa.

Como mejora del controlador *feedforward*, se propone sustituir el mapa estático por un modelo dinámico inverso del motor, consistente en una red neuronal recurrente del mismo tipo que la utilizada para el observador, aunque en este caso las entradas serían el ángulo de mariposa  $\alpha$ , el régimen de giro  $n$ , y la relación aire-combustible  $\lambda$ . La nueva salida es el tiempo de inyección  $t_i$ .

La red neuronal recurrente con especialización de las neuronas de contexto, utilizada para el observador, podría optimizarse en lo que se refiere a su estructura, mediante algoritmos de reducción y crecimiento. De igual forma, sería conveniente utilizar un algoritmo de aprendizaje avanzado, como puede ser el SARPROP [Tread98Sim], o el BPSOR [De98A Succ], diferente al clásico de retropropagación, que logre un menor error de identificación y evite la caída en mínimos locales.

Una mejora importante en el observador sería la utilización de una sonda EGO, en lugar de la UEGO, para el entrenamiento de la red neuronal, aplicando un algoritmo de aprendizaje basado en un crítico, en lugar del de retropropagación. De esta forma se lograría la aplicación inmediata a cualquier motor, sin necesidad de cambiar la sonda lambda original.

El apartado más importante que no ha podido realizarse por falta de tiempo es la experimentación de los algoritmos de control propuestos con un motor real. El primer paso sería la construcción física del controlador, utilizando para ello un hardware y un lenguaje de programación que permitan obtener la respuesta en tiempo real. Esto permitiría verificar que los resultados obtenidos en las simulaciones se cumplen en la planta real.

