

Universidad Central “Marta Abreu” de Las Villas

Facultad de Ingeniería Eléctrica

Departamento de Automática y Sistemas Computacionales



TRABAJO DE DIPLOMA

Identificación no lineal de un sistema con Zona Muerta

Autor: Oscar Esquivel Reina

Tutor: Dr. Francisco Herrera Fernández

Msc. Ailyn Gutiérrez Ferrera

Santa Clara

2015

"Año 57 de la Revolución"

Universidad Central “Marta Abreu” de Las Villas

Facultad de Ingeniería Eléctrica

Departamento de Automática y Sistemas Computacionales



TRABAJO DE DIPLOMA

Identificación no lineal de un sistema con Zona Muerta

Autor: Oscar Esquivel Reina

e-mail: oscare@uclv.edu.cu

Tutor: Dr. Francisco Herrera Fernández

Dpto. de Automática, Facultad de Ing. Eléctrica, UCLV

e-mail: herrera@uclv.edu.cu

Msc. Ailyn Gutiérrez Ferrera

e-mail: ailyngf@uci.cu

Santa Clara

2015

"Año 57 de la Revolución"

PENSAMIENTO

“Vivimos en una sociedad profundamente dependiente de la ciencia y la tecnología y en la que nadie sabe nada de estos temas. Ello constituye una fórmula segura para el desastre”.

Carl Sagan

DEDICATORIA

A mis padres por su apoyo y amor incondicional.

AGRADECIMIENTOS

Agradecer:

Primeramente a mis padres que tanto me apoyaron durante todo mis años de estudio, a mi hermana y a mi sobrina que a pesar de todo por lo que hemos pasado en estos últimos tiempos siempre han sido de gran apoyo y motivación para seguir adelante y no darme por vencido.

A mi familia en general, a lo que están y a los que por razones de la vida ya se han marchado.

A todos mis amigos y amigas, que no los menciono uno por uno porque me llevaría a extender la tesis a más de doscientas páginas y entonces no me podría graduar este año.

A mis otras dos familias de Santa Clara que me brindaron incondicionalmente su apoyo en todos estos años.

A Yainet que me ha dado el mayor regalo que puede recibir una persona en esta vida. Gracias a ti mi vida por estar a mi lado y hacerme una mejor persona.

A mis compañeros de aula, a todos en general.

A mi tutora Ailyn Gutiérrez y a mi cotutor Francisco Herrera por el apoyo brindado durante la realización de este trabajo.

A los profesores y trabajadores de la Facultad de Eléctrica, aunque no compartiéramos los mismos criterios en ciertos momentos.

RESUMEN

Esta tesis se centra en la identificación no lineal de sistemas, principalmente en el desarrollo y la implementación de las estructuras no lineales ARX (NARX) y Hammerstein-Wiener, para obtener modelos matemáticos de sistemas dinámicos. Para realizar la identificación de sistemas, en primer lugar, se requiere un conjunto de datos de entrada-salida que se obtienen experimentalmente del sistema, para después elegir la estructura a utilizar y por último un algoritmo de optimización de los parámetros.

Para ello, se explota la capacidad del *Toolbox* de Identificación de Sistemas de MATLAB de proporcionar los datos que más información brindan acerca del comportamiento de las diferentes estructuras.

Se realizó la identificación de dos sistemas no lineales (un sistema de primer orden con retardo y un sistema de segundo orden), la no linealidad viene dada por una Zona Muerta en varias de sus formas. También, se hicieron pruebas de validación para cada sistema con los modelos que se obtienen con el Toolbox de Identificación de Matlab®.

Finalmente, se realizó la comparación de los resultados con el objetivo de establecer el mejor modelo para identificar dichos sistemas.

Palabras claves: Identificación no lineal, sistemas, modelos, no linealidad, Zona Muerta, estructuras NARX y Hammerstein-Wiener.

TABLA DE CONTENIDOS

PENSAMIENTO	i
DEDICATORIA	ii
AGRADECIMIENTOS	iii
RESUMEN	iv
INTRODUCCIÓN	1
Organización del informe	5
CAPÍTULO 1. IDENTIFICACIÓN NO LINEAL DE SISTEMAS	6
1.1 Sistemas no lineales, tipos de no linealidades, características, clasificación	6
1.1.1 Caracterización de la no linealidad Zona Muerta	7
1.2 Identificación de Sistemas no lineales	7
1.2 Métodos de identificación no lineal para sistemas no lineales a utilizar	13
1.2.1 ¿Qué son los modelos no lineales?	13
1.2.2 Modelos no lineales	13
1.2.3 Modelos de espacio de estado no lineales	14
1.2.4 El modelo no lineal ARX (NARX) como extensión de la estructura lineal ARX 15	15
1.2.5 Estructura de los modelos no lineales ARX (NARX)	15
1.2.5.1 Estimadores no lineales para modelos no lineales ARX	17
1.2.6 Estructura de los modelos no lineales Hammerstein - Wiener	17
1.2.6.1 El modelo de Hammerstein-Wiener calcula la salida y en tres etapas	19
1.2.6.2 Estimadores no lineales para los modelos Hammerstein - Wiener	19
1.3 Consideraciones finales del capítulo	19

CAPÍTULO 2. IMPLEMENTACIÓN DE LOS MODELOS NO LINEALES	21
2.1 Presentación del software y herramientas utilizadas	21
2.2 Diseño en Simulink del diagrama en bloques para los distintos sistemas.....	22
2.3 Elección de la entrada y salida del modelo	23
2.4 Elección de la representación dinámica	24
2.5 Registro de datos entrada-salida.....	26
2.5.1 Tratamiento previo de los datos entrada-salida	26
2.6 Elección del orden del modelo	27
2.6.1 Selección de los modelos.....	27
2.6.2 Selección de sus parámetros	28
2.6.2.1 Modelo no lineal ARX (NARX).....	28
2.6.2.2 Modelo Hammerstein.....	29
2.6.2.3 Modelo Wiener.....	31
2.7 Validación de los modelos.....	33
2.8 Algoritmos de optimización	35
2.9 Consideraciones finales del capítulo	35
CAPÍTULO 3. RESULTADOS Y ANÁLISIS DE LAS SIMULACIONES	36
3.1 Resultados de la simulación de los modelos no lineales.....	36
3.2 Sistema de Primer Orden con Retardo	37
3.2.1 Zona Muerta al 0%	37
3.2.2 Zona Muerta al 25%	38
3.2.3 Zona Muerta al 50%	39
3.2.4 Zona Muerta al 90%	41
3.3 Sistema de Segundo Orden	42

3.3.1	Zona Muerta al 0%	42
3.3.2	Zona Muerta al 25%	43
3.3.3	Zona Muerta al 50%	45
3.3.4	Zona Muerta al 90%	46
3.4	¿Cuál es el modelo no lineal con mejor comportamiento ante los sistemas identificados?	47
3.5	Valoración económica.....	47
3.6	Consideraciones finales del capítulo.....	48
CONCLUSIONES Y RECOMENDACIONES		49
Conclusiones		49
Recomendaciones		50
REFERENCIAS BIBLIOGRÁFICAS		51
ANEXOS		54
Anexo I No linealidades más comunes.....		54
Anexo II Estimadores para NARX.....		56
Anexo III Estimadores para el Modelo Hammerstein- Wiener.....		58

INTRODUCCIÓN

En la actualidad el desarrollo tecnológico es constante, como consecuencia se desarrollan sistemas cada vez más complejos los cuales se requieren controlar. Hay diferentes métodos de control de sistemas, el más común y usado es el basado en el modelo, razón por la cual, una tarea importante en la comunidad de control automático es la obtención de modelos de sistemas dinámicos que permitan ser utilizados para su análisis, simulación, optimización, diagnóstico de fallas y en gran parte para el diseño de controladores. Para obtener un modelo matemático existen dos métodos principales, uno se basa en un modelado teórico que a partir de leyes físicas se describe el comportamiento dinámico de un fenómeno o proceso; otro es mediante identificación de sistemas, herramienta que se utiliza para la estimación y construcción de modelos en base a los datos de entrada y salida obtenidos de la experimentación con dicho sistema. De los dos métodos mencionados, se hace el enfoque a la identificación de sistemas la cual se divide principalmente en lineal y no lineal, las dos tienen igual importancia en la comunidad de control.

La identificación no lineal en la actualidad se ha convertido en una herramienta que debe ser usada, el motivo es porque los procesos cada vez son más complejos, y obtener su modelo por el método analítico se hace laborioso y complicado; es por ello, que se opta por experimentar directamente con el sistema a través de la identificación. La identificación es un método totalmente experimental, en el cual no se necesita de un conocimiento a detalle del sistema que se desea modelar. Si se compara con el método analítico, la identificación es más rápida(Ljung 2010). Por lo tanto, la identificación puede representar de manera adecuada al sistema real.

Desde los años 60 la identificación de sistemas se estableció como un campo de investigación, reconocido dentro del área de control automático y a mediados de los sesenta, en el tercer congreso de la IFAC en Londres 1966 en el que por primera vez se presentó un artículo de visión general sobre identificación de sistemas, mientras que en los años 70 se obtuvo una aplicación de identificación en sistemas de una entrada y una salida (SISO). Fue hasta la década de los 90 cuando de manera oficial se utilizó esta técnica en procesos industriales (Nelles 2001).

Narendra y Parthasarathy en la época de los 90 demuestran que las redes neuronales pueden ser usadas en identificación y control de sistemas dinámicos, el enfoque que presentan es hacer identificación usando el algoritmo de aprendizaje retro propagación del error (back-propagation) método utilizado para el ajuste de los parámetros (Narendra and Parthasarathy 1990).

Martin T. Hagan y Mohammad B. Menhaj presentan el algoritmo de Levenberg-Marquardt que se basa en el algoritmo de retro propagación del error para entrenar redes neuronales con realimentación. Además de que dicho algoritmo es comparado con el algoritmo de gradiente conjugado. Por otro lado presentan que el algoritmo de Levenberg-Marquardt es más eficiente que el gradiente conjugado cuando la red contiene unos 100 pesos sinápticos (Hagan and Menhaj 1994).

Juditsky, Hakan, Albert, Bernard, Lennart, Jonas y Qinghua muestran varios aspectos de los fundamentos matemáticos del problema de identificación no lineal, puesto que un factor para obtener una buena estimación está en base a un buen algoritmo de identificación. También muestran que los sistemas de identificación tipo caja negra (Black Box) normalmente son considerados en estructuras como redes neuronales, redes de base radial, redes wavelet, así como métodos basados en la transformación de wavelet y modelos utilizando lógica difusa (Juditsky, Hjalmarsson et al. 1995), (Sjöberg, Zhang et al. 1995).

Cohello y Pessa, en 2009 realizan identificación no lineal del sistema llamado “tubo y bola”, un prototipo de bajo costo. Ellos conectan en paralelo el sistema real y la estructura NARX que utilizan para identificar dicho sistema, al mismo tiempo obtienen el error de la diferencia entre la salida del sistema real y la salida estimada con la estructura NARX (dos Santos Coelho and Pessôa 2009).

Jozef Vörös en 2004 explica cómo hacer identificación de sistemas dinámicos usando la estructura Hammerstein-Wiener; también, muestra la aplicación de una técnica de descomposición que proporciona expresiones especiales para la descripción de modelos que son lineales en los parámetros(Vörös 2004).

Andrzej Janczak en su libro “Identificación de sistemas no lineales usando redes neuronales y modelos polinomiales” con un enfoque a bloques orientados, muestra dos tipos de modelos: Wiener y Hammerstein; también, presenta una combinación donde el bloque lineal es representado por polinomios (función de transferencia) y el bloque no lineal por una red neuronal con una tangente hiperbólica en la capa oculta(Janczak 2004).

Emad Abd-Elrady and Li Gan presenta una alternativa de hacer identificación no lineal con los modelos Hammerstein y Wiener, utilizan el algoritmo generalizado de Newton para la estimación de los parámetros(Abd-Elrady and Gan 2008).

En CENIDET del año 2005 al 2010 se han desarrollado trabajos de identificación de los cuales se encuentran las siguientes tesis de maestría, “Identificación de sistemas utilizando redes neuronales”(Ugalde 2008), e “Identificación de sistemas en lazo cerrado con estructura tipo CLOE”(López 2007).

En el ámbito nacional aparecen pocas investigaciones relacionadas con el tema, R. Ernesto Rubio, S. Luis Hernández, S. Rafael Aracil, P. Roque Saltarén, Q. Raúl Moreno presentan el “Modelado, Identificación y Control de Actuadores Lineales Electroneumáticos. Aplicación en Plataforma de Dos Grados de Libertad”, donde se realiza el análisis del modelo físico de estos sistemas con un nuevo enfoque: considerando la diferencia entre las constantes de tiempo de las cámaras del cilindro y el subdimensionado del carrete de la válvula, obteniendo como resultado un modelo que describe de forma más precisa la dinámica de estos sistemas(Rubio, Hernández et al. 2007).

Luego de realizar un análisis bibliográfico del panorama nacional e internacional en torno al tema en cuestión, no se encontró antecedente alguno que hablara de la existencia de un criterio que sugiera el empleo del mejor método a emplear para una zona muerta específica, en determinada posición dentro de un sistema o proceso, por lo que se define como **situación problemática**: La no existencia en la actualidad de un criterio que sugiera el empleo del mejor método implementado en la herramienta de Identificación de Sistemas de MATLAB para

identificar una zona muerta específica, en determinada posición dentro de un sistema o proceso.

Partiendo de estas conclusiones se diseñó y se llevó a cabo la presente investigación en la Universidad Central “Marta Abreu” de Las Villas, a partir del siguiente **problema científico**:

¿Cuál es el mejor método de identificación no lineal a emplear para una zona muerta específica, en determinada posición dentro de un sistema o proceso?

Asimismo la investigación responde a determinada interrogante científica para su desarrollo:

Interrogante Científica:

¿Cuál es el nivel de aplicabilidad de los métodos actuales de identificación no lineal para un sistema con zona muerta?

Con el propósito de dar solución a la situación problemática, se plantea como **objetivo general**, aplicar métodos de identificación no lineal ya conocidos e implementados en MATLAB a sistemas que presentan no linealidades severas como característica predominante, en particular zona muerta en varias de sus formas. En tanto, los **objetivos específicos** son:

- Aplicar técnicas de identificación no lineal, tales como, NARX, funciones de Wiener y Hammerstein en sistemas que presenta zona muerta en varias de sus formas.
- Comparación de los resultados arrojados de cada técnica empleada en la identificación para un sistema de ejemplo (caso de estudio).

Al concluir la investigación se deben conocer como **resultados** las técnicas más eficientes de identificación no lineal para ejemplos específicos de sistemas que poseen zona muerta.

Como **impacto posible** se contribuirá a una mejor selección del método de identificación no lineal más adecuado en una aplicación concreta de estimación paramétrica, para sistemas con zona muerta. Además se podrá determinar la posibilidad de mejorar las técnicas actuales de identificación de sistemas para el caso de procesos con no linealidades severas como zona muerta.

Según su **aplicabilidad**, los resultados de la investigación realizada pueden aplicarse en cualquier rama donde figuren sistemas con zona muerta, fundamentalmente para la estimación de los modelos matemáticos de los mismos.

Se cuenta con los recursos humanos y materiales necesarios. Asimismo el proyecto se ajusta a demandas actuales y se ubica racionalmente en el tiempo y en el contexto social, por lo que puede afirmarse su **viabilidad**.

Organización del informe

El informe de la investigación está estructurado de la siguiente manera: La presente introducción a la que siguen, en el mismo orden, capitulario, conclusiones, recomendaciones, referencias bibliográficas y anexos.

Los temas abordados en cada uno de los capítulos son:

CAPÍTULO 1. IDENTIFICACIÓN NO LINEAL DE SISTEMAS

En este capítulo se aborda el tema de la Identificación no Lineal de Sistemas usando como referencia la literatura clásica para dicho tema. Se investiga sobre las potencialidades que MATLAB ofrece relacionadas con la Identificación no Lineal de Sistemas y se presentan los principales modelos no lineales utilizados.

CAPÍTULO 2. IMPLEMENTACIÓN DE LOS MODELOS NO LINEALES

En dicho capítulo se explican el diseño y configuración de los modelos implementados, siguiendo los principales pasos para la identificación. Se determina la información relevante a almacenar sobre cada modelo.

Capítulo 3. RESULTADOS Y ANÁLISIS DE LAS SIMULACIONES

En este capítulo se muestran los resultados obtenidos y se realiza la comparación de los mismos para establecer el mejor método a utilizar. Para calcular los costos de la investigación se realiza una valoración económica, dando cierre al capítulo.

CAPÍTULO 1. IDENTIFICACIÓN NO LINEAL DE SISTEMAS

La Identificación de Sistemas es una vía para obtener modelos de los procesos, la misma se realiza fundamentalmente a partir del procesamiento de datos experimentales de entrada y salida del sistema a modelar.

Los métodos de identificación de sistemas son bastantes numerosos y se aplican con buenos resultados en sistemas bien definidos. Sin embargo, en la práctica hay un grupo de sistemas que, o bien presentan incertidumbre en sus variables o bien presentan indefinición en su estructura y se hace problemática su identificación.

En este capítulo se expone a grandes rasgos todo lo relacionado con la Identificación de Sistemas no lineales, también se hace un breve recorrido por las no linealidades y en especial se enfatiza en la Zona Muerta. Para culminar el capítulo se prevé dar una reseña de los métodos implementados en Matlab con los cuales se trabajará.

1.1 Sistemas no lineales, tipos de no linealidades, características, clasificación

En cualquier proceso pueden encontrarse no linealidades, estas pueden ser intencionadas o inherentes. Las no linealidades intencionadas se emplean, por ejemplo en un sistema de control, para mejorar su respuesta y/o para simplificar su construcción. Las no linealidades inherentes son aquellas que se manifiestan de forma natural en el proceso, por lo que son inevitables. Las siguientes son ejemplos de tales no linealidades: saturación; zona muerta; histéresis; juego; fricción estática, fricción de Coulomb; resorte no lineal; compresibilidad de fluido; fuerza centrípeta en movimiento rotacional(Thaler and Pastel 1962).

También se pueden clasificar las no linealidades como blandas o “severas”. Si un elemento se desvía gradualmente de la operación lineal cuando el nivel de excitación aumenta se puede

decir que se está en presencia de una no linealidad blanda. Las no linealidades severas se observan cuando los elementos cambian abruptamente en un nivel específico de excitación. Las no linealidades severas también se les conoce como no linealidades rápidas, pues el modo de operar cambia rápidamente comparándolo con el tiempo de respuesta del sistema. Las no linealidades severas que más regularmente se manifiestan en los procesos son: saturación; zona muerta; histéresis; fricción de Coulomb(Thaler and Pastel 1962). Algunas de estas se muestran en el [Anexo I](#).

1.1.1 Caracterización de la no linealidad Zona Muerta

La no linealidad zona muerta es también un tipo común de característica no lineal que se produce en muchas aplicaciones prácticas. La no linealidad zona muerta ideal se da en la figura 1.1.(Kara and Eker 2004). La zona muerta es la señal de entrada mínima que se requiere para que el sistema responda.

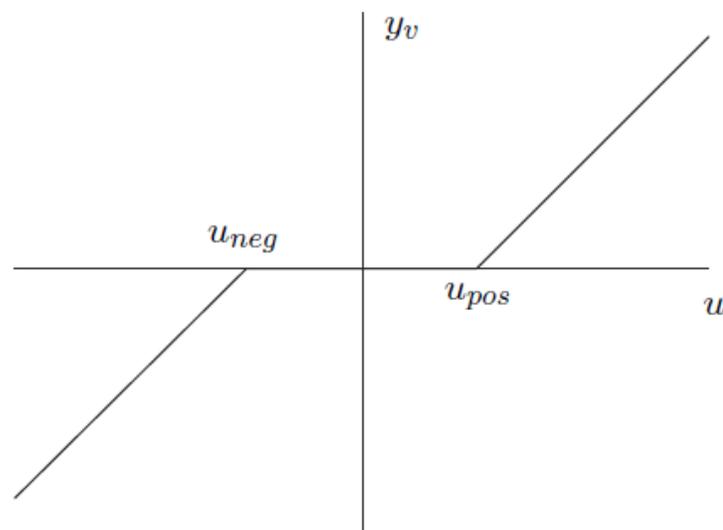


Figura 1.1. Zona Muerta.

Tal característica es típica de las válvulas y algunos amplificadores de señales de baja de entrada y se produce en muchos sistemas mecánicos. Donde U_{pos} y U_{neg} son los umbrales a partir de los cuales la señal de control comienza a ser efectiva(Kara and Eker 2004).

1.2 Identificación de Sistemas no lineales

Un sistema es toda realidad en la que interactúan variables de diferentes tipos para producir señales observables; de estas, las que son de interés para el observador se denominan salidas

del sistema, mientras que aquellas otras señales del sistema que pueden ser manipuladas libremente por el observador son las entradas del mismo. El resto de señales que influyen en la evolución de las salidas y no pueden ser manipuladas se denominan perturbaciones, esto se muestra en la figura 1.2.(Acoltzi 2011).

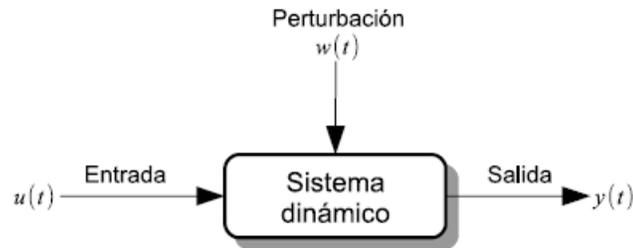


Figura 1.2. Sistema dinámico.

Los modelos de sistemas reales son de gran importancia en casi todas las disciplinas, porque, con dichos modelos se tiene un mejor entendimiento del sistema real, también hacen posible simular el comportamiento de los sistemas. La identificación de sistemas dinámicos no lineales es una tarea difícil, debido a que estos son únicos en el sentido de que no comparten muchas propiedades(Ljung 2007).

Cuando se hace necesario conocer el comportamiento de un sistema en unas determinadas condiciones y ante unas determinadas entradas, se puede recurrir a la experimentación sobre dicho sistema y a la observación de sus salidas. Sin embargo, en muchos casos la experimentación puede resultar compleja o incluso imposible de llevar a cabo, lo que hace necesario trabajar con algún tipo de representación que se aproxime a la realidad, y a la que se conoce como modelo(Acoltzi 2011).

La identificación de sistemas es la construcción de modelos matemáticos de los sistemas dinámicos basados en datos de entrada-salida observados. En caso de que el modelo buscado es lineal, existen bien estructurado teorías, metodologías y algoritmos. Para el caso de modelos no lineales, la situación es más compleja, y quizás confusa. En particular, hay varias técnicas intrigantes que se han desarrollado fuera del área de investigación para la identificación de sistema, sobre todo en la comunidad de aprendizaje automático(Ljung 1997).

Conceptos como el Aprendizaje Múltiple y Procesos Gaussianos han llegado a ser valiosos también para la identificación no lineal de sistemas. Los siguientes epígrafes tienen como

objetivo una visión general de los diversos enfoques para la identificación de sistemas no lineales (Ljung 1997).

Hay varios tipos de modelos de sistemas dinámicos, una clasificación de ellos se describe a continuación:

1. Modelos mentales, intuitivos o verbales. Estos modelos carecen de formalismo matemático. Para conducir un coche, por ejemplo, se requiere un modelo mental o intuitivo sobre el efecto que produce el movimiento del volante, pero no es necesario caracterizar dicho efecto mediante ecuaciones matemáticas exactas.

2. Modelos no paramétricos. Muchos sistemas quedan perfectamente caracterizados mediante un gráfico o tabla que describa sus propiedades dinámicas mediante un número no finito de parámetros.

Por ejemplo, un sistema lineal queda definido mediante su respuesta al impulso o al escalón, o bien mediante su respuesta en frecuencia.

3. Modelos paramétricos o matemáticos. Para aplicaciones más avanzadas, puede ser necesario utilizar modelos que describan las relaciones entre las variables del sistema mediante expresiones matemáticas como pueden ser ecuaciones diferenciales (para sistemas continuos) o en diferencias (para sistemas discretos). En función del tipo de sistema y de la representación matemática utilizada, los sistemas pueden clasificarse en:

a) Determinísticos y Estocásticos. Se dice que un modelo es determinístico cuando expresa la relación entre entradas y salidas mediante una ecuación exacta. Por contra, un modelo es Estocástico si posee un cierto grado de incertidumbre. Estos últimos se definen mediante conceptos probabilísticos o estadísticos.

b) Dinámicos y estáticos. Un sistema es estático cuando la salida depende únicamente de la entrada en ese mismo instante (por ejemplo, un resistor). En estos sistemas existe una relación directa entre entrada y salida, independiente del tiempo. Mientras que un sistema dinámico es aquél en el que las salidas evolucionan con el tiempo tras la aplicación de una determinada entrada (por ejemplo, una red RC). En éstos, para conocer el valor actual de la salida es necesario conocer el tiempo transcurrido desde la aplicación de la entrada.

c) Continuos y discretos. Los sistemas continuos trabajan con señales continuas, y se caracterizan mediante ecuaciones diferenciales. Los sistemas discretos trabajan con señales que se muestrean, y quedan descritos mediante ecuaciones en diferencias.

1.3 Modelos paramétricos

En esta tesis sólo se trabaja con el método paramétrico como muestra la figura 1.3, la razón principal es porque dicho método requiere tener la planta o proceso a identificar, y define una posible estructura. Además de que se obtiene un modelo, en cambio el método no paramétrico se caracteriza mediante un gráfico o tabla que describa sus propiedades dinámicas, mediante un número no finito de parámetros. Por ejemplo un sistema se define por el análisis de la respuesta transitoria, análisis espectral, análisis de Fourier, entre otros (Murray-Smith and Johansen 1997).

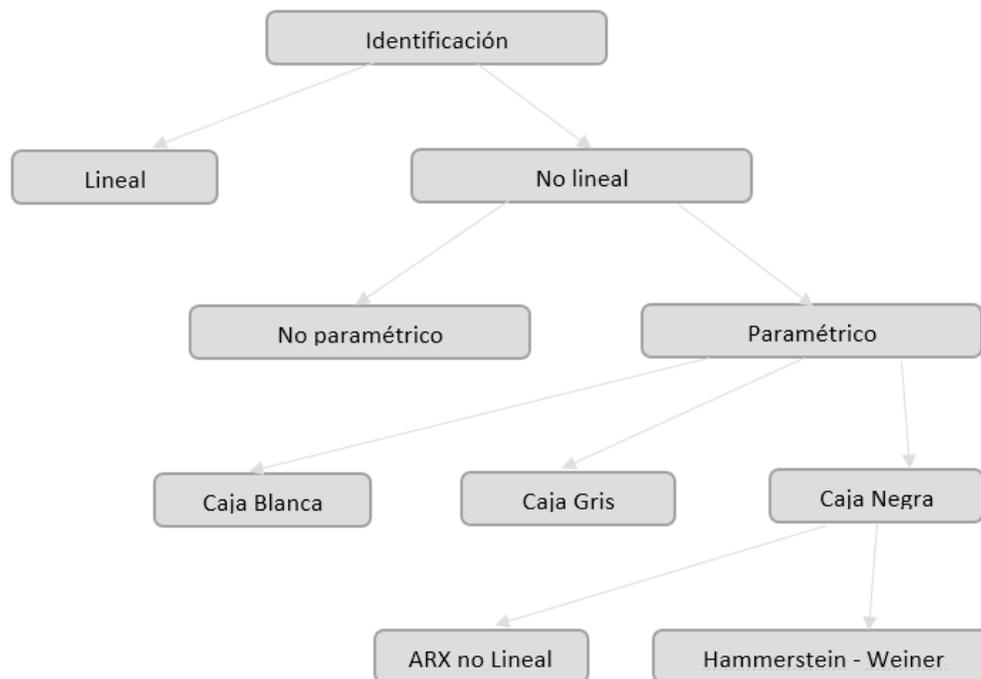


Figura 1.3. Diagrama en bloques para la identificación.

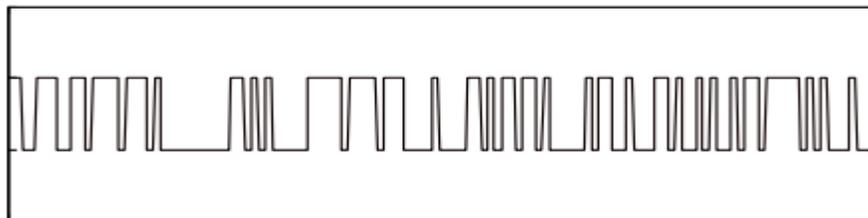
1.3.1 Pasos para realizar la identificación de sistemas no lineales.

Por otro lado, se siguen pasos para identificar sistemas dinámicos no lineales los cuales se enuncian a continuación (Acoltzi 2011):

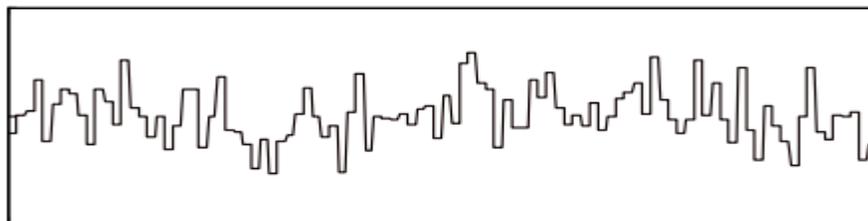
1. Elección de la entrada y salida del modelo. Dentro de este paso se obtienen los datos de entrada-salida. Es necesario que la entrada al sistema durante la toma de datos tenga un espectro plano en la banda pasante del sistema para asegurar que todos los modos propios del sistema son excitados dando una señal de salidas con suficiente información como para

caracterizar la dinámica del sistema o proceso (Cubero 1993). Las entradas al sistema deben ser cuidadosamente elegidas de forma que los datos recogidos proporcionen toda la información posible sobre el sistema. Respecto a este, conviene tener en cuenta los siguientes aspectos:

- La señal de entrada debe contener el mayor número de frecuencias posibles. Por ejemplo, una señal sinusoidal pura no es adecuada en un experimento de identificación, puesto que sólo se obtendrá la respuesta del sistema para la frecuencia de dicha señal. Por el contrario, las señales escalonadas (con cambios bruscos) son muy utilizadas, puesto que contienen un espectro suficientemente amplio de frecuencias.
- Para sistemas lineales, basta con utilizar dos niveles de entrada, preferiblemente barriendo todo el rango de variación permitido. En este tipo de sistemas se suelen utilizar señales binarias de duración aleatoria (conocidas como señales binarias aleatorias o pseudoaleatorias), como la mostrada en la figura 1.4. a). Sin embargo, para sistemas no lineales es necesario trabajar con más de dos niveles de entrada, como se muestra en la figura 1.4. b).



(a)



(b)

Figura 1.4. a): Entrada aleatoria binaria para sistemas lineales. **b):** Entrada escalonada aleatoria para sistemas no lineales.

- Si se sabe que el sistema va a trabajar preferentemente en torno a un determinado punto de trabajo, es conveniente realizar el registro de datos en ese mismo entorno.

Este aspecto adquiere especial importancia si el sistema no es lineal.

2. Tratamiento de los datos obtenidos. Los datos obtenidos en el paso anterior muchas veces vienen acompañados de ruidos por lo que deben ser tratados y preparados para facilitar y mejorar los procesos de identificación.

3. Elección de la representación dinámica. En este caso se elige la estructura no lineal con la que se desea trabajar, para ello se recomienda leer antes sobre cada una de las estructuras existentes.

4. Elección del orden del modelo. En este paso se aplica el algoritmo para la optimización de los parámetros al mismo tiempo esto nos lleva a dos pasos:

a) Selección del mejor modelo.

b) Selección de los parámetros.

Este es un paso previo a las tareas de experimentación y debes tener en cuenta la complejidad del proceso real y de la estimación de parámetros, así como el uso final que se le desee dar al modelo(Cubero 1993).

5. Validación del modelo. Finalmente, se hacen todas las pruebas necesarias para determinar si el modelo obtenido es una buena representación del modelo real; si se llega a la conclusión de que el modelo no es válido, se deben revisar los siguientes aspectos como posibles causas:

a) El conjunto de datos de entrada-salida no proporciona suficiente información sobre la dinámica del sistema.

b) La estructura seleccionada no es capaz de proporcionar una buena descripción del modelo.

c) El criterio de ajuste de los parámetros seleccionado no es el más adecuado.

Para realizar identificación de sistemas no lineales se requieren soluciones diferentes a los de un sistema lineal por lo que se utilizan diferentes herramientas encontradas en diversas disciplinas. Las técnicas de identificación que se encuentran en la literatura son: NARMAX (no lineal autorregresivo de media móvil exógena), NARX (No lineal autorregresivo con entrada exógena), NOE (no lineal con error de salida), redes neuronales artificiales, modelos

difusos, series de Volterra, los modelos orientados a bloques Hammerstein y Wiener y la combinación de ambas, entre otros (Acoltzi 2011).

1.2 Métodos de identificación no lineal para sistemas no lineales a utilizar

Para comenzar a hablar de los métodos de identificación no lineal que se tratarán, hay que conocer:

1.2.1 ¿Qué son los modelos no lineales?

Los modelos dinámicos son las relaciones matemáticas entre las entradas del sistema $u(t)$ y las salidas de $y(t)$ (Lennart 2014). Usted puede utilizar estas relaciones para calcular la salida de las entradas y salidas anteriores. La forma general de un modelo en tiempo discreto es:

$$y(t) = f(u(t-1), y(t-1), u(t-2), y(t-2), \dots) \quad (1.1)$$

Tal modelo no es lineal si la función f es una función no lineal, f puede representar linealidades arbitrarias, tales como interruptores, saturaciones y zonas muertas.

En la práctica, todos los sistemas son no lineales y la salida es una función no lineal de la entrada variable. Sin embargo, un modelo lineal es a menudo suficiente para describir con precisión el sistema dinámico. En la mayoría de los casos, primero se debe tratar de ajustar los modelos lineales (Lennart 2014).

Es posible que tenga modelos no lineales cuando un modelo lineal proporciona un mal ajuste de la medición de las señales de salida y no se puede mejorar cambiando la estructura del modelo u orden. Los modelos no lineales tienen más flexibilidad en la captura de los fenómenos complejos que los modelos lineales de órdenes similares.

1.2.2 Modelos no lineales

Los modelos no lineales ARX (NARX)

Los modelos no lineales ARX (NARX) son una extensión de los modelos lineales ARX para casos no lineales y tienen esta estructura:

$$y(t) = f(y(t-1), \dots, y(t-na), u(t-nk), \dots, u(t-nk-nb+1)) \quad (1.2)$$

Donde la función f depende de un número finito de entradas anteriores u y salidas y , na es el número de términos de salida pasadas y nb es el número de términos de entrada, últimos utilizados para predecir la salida de corriente, nk es el retardo desde la entrada hasta la salida, especificado como el número de muestras.

Normalmente, se utiliza modelos no lineales ARX (NARX) como estructuras de caja negra (Black Box). La función *no linealidad* del modelo no lineal ARX es un estimador flexible, que no tiene por qué tener un significado físico (Lennart 2014).

Modelos Hammerstein – Wiener

Modelos Hammerstein - Wiener describen sistemas dinámicos utilizando uno o dos bloques estáticos no lineales en serie con un bloque lineal. El bloque lineal es una función de transferencia discreta y representa el componente dinámico del modelo.

Se puede utilizar la estructura Hammerstein - Wiener para capturar los efectos no lineales físicos en sensores y actuadores que afectan a la entrada y salida de un sistema lineal, tal como zonas muertas y saturación. Se utiliza los modelos Hammerstein - Wiener como estructuras de caja negra (Black Box), que no representan una visión física en los procesos del sistema (Lennart 2014).

1.2.3 Modelos de espacio de estado no lineales

Modelos de espacio de estado no lineales tienen esta representación:

$$\dot{x}(t) = F(x(t), u(t)) \quad (1.3)$$

$$y(t) = H(x(t), u(t)) \quad (1.4)$$

Donde F y H pueden tener cualquier parametrización. Una ecuación diferencial ordinaria no lineal de alto orden se puede representar como un conjunto de ecuaciones de primer orden. Los parámetros de estos modelos tienen típicamente interpretaciones físicas.

1.2.4 El modelo no lineal ARX (NARX) como extensión de la estructura lineal ARX

Un modelo no lineal ARX (NARX) puede ser entendido como una extensión de un modelo lineal. Un modelo lineal SISO ARX tiene esta estructura:

$$y(t) + a_1y(t-1) + a_2y(t-2) + \dots + a_{na}y(t-na) = b_1u(t) + b_2u(t-1) + \dots + b_{nb}u(t-nb+1) + e(t) \quad (1.5)$$

Donde el nk retardo de entrada es cero para simplificar la notación.

Esta estructura implica que la corriente de salida $y(t)$ se predice como una suma ponderada de valores pasados de salida y valores de entrada, actuales y pasados. Reescribiendo la ecuación como un producto:

$$y_p(t) = [-a_1, -a_2, \dots, -a_{na}, b_1, b_2, \dots, b_{nb}] * [y(t-1), y(t-2), \dots, y(t-na), u(t), u(t-1), \dots, u(t-nb-1)]^T \quad (1.6)$$

Donde $y(t-1), y(t-2), \dots, y(t-na), u(t), u(t-1), \dots, u(t-nb-1)$ son las variables con retardo de entrada y salida, llamadas regresores. Así pues, el modelo ARX lineal predice la salida de corriente y_p como una suma ponderada de sus regresores.

Esta estructura puede ser extendida para crear una forma no lineal como:

- En lugar de la suma ponderada que representa una aplicación lineal, el modelo no lineal ARX (NARX) tiene una función de mapeo no lineal más flexible:

$$y_p(t) = f(y(t-1), y(t-2), y(t-3), \dots, u(t), u(t-1), u(t-2), \dots) \quad (1.7)$$

Donde f es una función no lineal. Las entradas a f son regresores del modelo, al especificar la estructura del modelo no lineal ARX (NARX).

- Regresores en la estructura no lineal ARX (NARX) pueden ser las dos variables de entrada-salida con retraso, y más complejos, las expresiones no lineales de las variables de entrada y de salida demorada (Lennart 2014). Ejemplos de tales regresores no lineales son:

$$y(t-1)^2, u(t-1) * y(t-2), \tan(u(t-1)), u(t-1) * y(t-3)$$

1.2.5 Estructura de los modelos no lineales ARX (NARX)

Este diagrama de bloques representa la estructura de un modelo no lineal ARX (NARX) en un escenario de simulación (MOORE, 2010):

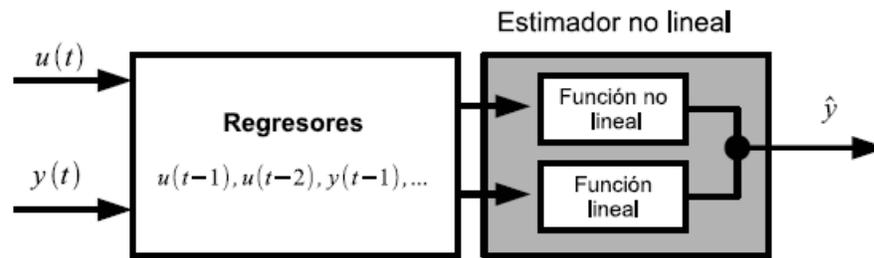


Figura. 1.5. Representación de la estructura no lineal ARX (NARX).

El modelo no lineal ARX (NARX) calcula la salida y en dos etapas:

- Calcula los valores de los regresores de entradas actuales y anteriores, y los datos de salida del pasado. En el caso más simple, los regresores son las entradas y salidas, tales como un retraso $u(t-1)$, $y(t-3)$ -llamado regresores estándar. También puede especificar regresores personalizados, que son funciones no lineales de retraso en las entradas y salidas. Por ejemplo, $\tan(u(t-1))$ o $u(t-1) * y(t-3)$.
- Por defecto, todos los regresores son entradas tanto de la función lineal como del bloque no lineal del estimador no lineal. Usted puede elegir un subconjunto de regresores como entradas al bloque de función no lineal.
- El bloque estimador *no linealidad* brinda mapas de los regresores a la salida del modelo, utilizando una combinación de funciones no lineales y lineales. Puede seleccionar entre los estimadores no lineales disponibles, como las redes de árbol de particiones (Tree Partition), redes de tren de ondas (Wavelet Networks), y redes neuronales multicapa (Multi-layer Neural Networks). También puede excluir los bloques de función ya sea lineal o no lineal desde el estimador de *no linealidad*.

El bloque estimador *no linealidad* puede incluir bloques lineales y no lineales en paralelo.

Por ejemplo:

$$F(x) = L^T(x - r) + d + g(Q(x - r)) \quad (1.8)$$

Donde x es un vector de las variables explicativas, $L^T(x) + d$ es la salida del bloque de función lineal cuando $d \neq 0$, d es un desplazamiento escalar, $g(Q(x - r))$ representa la salida

del bloque no lineal de funciones, r es la media de los regresores x , Q es una matriz de proyección que hace los cálculos bien acondicionados. La forma exacta de $F(x)$ depende de la elección del estimador de *no linealidad*.

Al estimar un modelo no lineal ARX (NARX) se calculan los valores de los parámetros del modelo, como la L , r , d , Q , y otros parámetros que especifican g .

1.2.5.1 Estimadores no lineales para modelos no lineales ARX

El Toolbox de identificación (Lennart 2014), tiene a disposición 6 estimadores que son utilizados para la estructura NARX, los cuales son Wavelet Network, One Layer Sigmoid Network, Tree Partition, Linear, Custom Network, Multilayered Neural Network, este último está indirectamente ya que requiere de otra herramienta para su funcionamiento.

Cada estimador no lineal se corresponde con una clase de objeto en esta caja de herramientas. Al estimar modelos no lineales ARX en la aplicación, el sistema de caja de herramientas de identificación (System Toolbox) crea y configura los objetos en función de estas clases. La mayoría de los estimadores de *no linealidad* representan la función no lineal como una serie sumadora de unidades no lineales, tales como las redes de tren de ondas o funciones sigmoideas. Puede configurar el número de unidades no lineales n para la estimación. Para más detalles ver [Anexo II](#).

1.2.6 Estructura de los modelos no lineales Hammerstein - Wiener

Cuando la salida de un sistema depende de manera no lineal en sus entradas, a veces es posible para descomponer la relación de entrada-salida en dos o más elementos interconectados. En este caso, se puede representar la dinámica de una función de transferencia lineal y capturar las linealidades utilizando funciones no lineales de las entradas y salidas del sistema lineal. Los Modelos de Hammerstein-Wiener logran esta configuración como una conexión en serie de bloques estáticos no lineales con un bloque lineal dinámico. Estos modelos son muy populares porque tienen una representación convenientemente en bloque, relación transparente con los sistemas lineales, y son más fácil de implementar que los modelos no lineales de carga pesada (como las Redes Neuronales y Modelos Volterra). Este diagrama de bloques representa la estructura de un modelo de Hammerstein -Wiener:



Figura 1.6. Representación de la estructura del modelo no lineal Hammerstein-Wiener.

Donde:

- $k(t) = f(u(t))$ es una función no lineal de datos de entrada transformación de $u(t)$ y $k(t)$ tiene la misma dimensión que $u(t)$.
- $x(t) = (B/F)k(t)$ es una función de transferencia lineal, $x(t)$ tiene la misma dimensión que $y(t)$.

Donde B y F son similares a polinomios en el modelo lineal Salida – Error.

Para las salidas n_y y entradas n_u , el bloque lineal es una matriz de funciones de transferencia que contiene entradas:

$$\frac{B_{j,i}(q)}{F_{j,i}(q)} \quad (1.9)$$

Donde $j = 1, 2, \dots, n_y$ y $i = 1, 2, \dots, n_u$.

- $Y(t) = h(x(t))$ es una función no lineal que correlaciona la salida del bloque lineal a la salida del sistema, $k(t)$ y $x(t)$ son variables internas que definen la entrada y la salida del bloque lineal, respectivamente.

Debido a F en el puerto de entrada del bloque lineal, esta función se llama la entrada *no linealidad*. Del mismo modo, porque h actúa sobre el puerto de salida del bloque lineal, esta función se llama la *no linealidad* de salida. Si el sistema contiene varias entradas y salidas, debe definir las funciones f y h para cada señal de entrada y de salida.

Usted no tiene que incluir tanto la *no linealidad* de entrada como la salida en la estructura del modelo. Cuando un modelo contiene sólo la *no linealidad* de entrada f , se llama un Modelo Hammerstein. Del mismo modo, cuando el modelo contiene sólo la *no linealidad* de salida h , se denomina un modelo de Wiener.

Las *no linealidades* f y h son funciones escalares, una función no lineal para cada entrada y canal de salida.

1.2.6.1 El modelo Hammerstein-Wiener calcula la salida y en tres etapas

1 Calcula $k(t) = f(u(t))$ a partir de los datos de entrada, $k(t)$ es una entrada a la función de transferencia lineal B/F . La *no linealidad* de entrada es una función estática (sin memoria), donde el valor de la salida de un tiempo dado t depende sólo sobre el valor de entrada en el tiempo t .

Puede configurar la *no linealidad* de entrada como una red sigmoidea (Sigmoid Network), la red de ondas (Wavelet Network), saturación (Saturation), zona muerta (Dead Zone), la función lineal por tramos (Piecewise Linear Function), polinomio unidimensional (One-Dimensional Polynomial), o una red personalizada (Custom Network). También puede eliminar la *no linealidad* de entrada.

2 Calcula la salida del bloque lineal utilizando $k(t)$ y las condiciones iniciales:

$$x(t) = (B/F) k(t). \quad (1.10)$$

Puede configurar el bloque lineal especificando los órdenes del numerador B y el denominador F .

3 Calcular la salida del modelo mediante la transformación de la salida del bloque lineal $x(t)$ utilizando la función no lineal h : $y(t) = h(x(t))$. Similar a la no linealidad de entrada, la no linealidad de salida es una función estática.

Configurar la no linealidad de salida en la misma forma que la no linealidad de entrada. También se puede eliminar la no linealidad de salida, tal que $y(t) = x(t)$.

1.2.6.2 Estimadores no lineales para los modelos Hammerstein - Wiener

Para la estructura Hammerstein – Wiener el ToolBox proporciona ocho estimadores no lineales escalares $F(x)$. Los estimadores de *no linealidad* están disponibles tanto para las no linealidades de entrada y salida (f y h), respectivamente (Lennart 2014). Para más detalles ver [Anexo III](#).

1.3 Consideraciones finales del capítulo

Partiendo de un análisis del capítulo se arriban a las siguientes consideraciones:

-
- La identificación de sistemas trata con el problema de construir modelos matemáticos de sistemas dinámicos basándose en datos observados del sistema. Es importante lograr una buena identificación que proporcione modelos de orden reducido más fáciles de utilizar.
 - Es de gran importancia almacenar los datos provenientes de la identificación para su posterior análisis (comparación) o para ser usado en futuras investigaciones.
 - El MATLAB es un software matemático de gran potencialidad y posee el Toolbox de Identificación de Sistemas (System Identification Tool) como poderosa herramienta que permite configurar los modelos a utilizar para la identificación, con un mayor acercamiento al modelo del sistema a identificar.
 - El estudio de estos modelos no lineales y sus respectivas estructuras permite lanzar la siguiente hipótesis, la cual se basa en el funcionamiento del estimador Dead Zone para el modelo no lineal Hammerstein, dicha hipótesis predice que el modelo que mejor caracteriza los sistemas con Zona Muerta, es el modelo no lineal Hammerstein. Esta se comprueba con los resultados de las simulaciones al final del Capítulo 3.

CAPÍTULO 2. IMPLEMENTACIÓN DE LOS MODELOS NO LINEALES

El desarrollo de las simulaciones o procesos de identificación parte de las consideraciones teóricas presentadas con anterioridad, las cuales demuestran aspectos básicos dentro del ámbito de la identificación no lineal de sistemas. En este capítulo se da una resumida caracterización del Toolbox de Identificación de Sistemas que es la herramienta utilizada durante todo el proceso de identificación.

A partir del segundo epígrafe comienza la implementación de los pasos a seguir para llevar a cabo dichas simulaciones, los cuales fueron explicados con anterioridad en el Capítulo 1.

2.1 Presentación del software y herramientas utilizadas

Como bien se explica en el capítulo anterior el software que se utiliza es el MatLab® 2010 y como herramienta se usa el Toolbox (Caja de Herramientas) de Identificación de dicho programa mediante la función *ident* la cual nos proporciona una avanzada ventana de trabajo como la que se muestra en la figura 2.1.

El Toolbox de Identificación de Sistemas (System Identification Tool) extiende el ambiente computacional de MATLAB y nos permite estimar modelos lineales y no lineales que relacionan las entradas y salidas de sistemas dinámicos (Ljung 2007). Tiene implementado métodos de estimación de modelos paramétricos y no paramétricos, provee un ambiente interactivo para análisis de datos, estimación y validación de modelos, facilita la estimación de modelos continuos y discretos, usando datos en el dominio del tiempo.

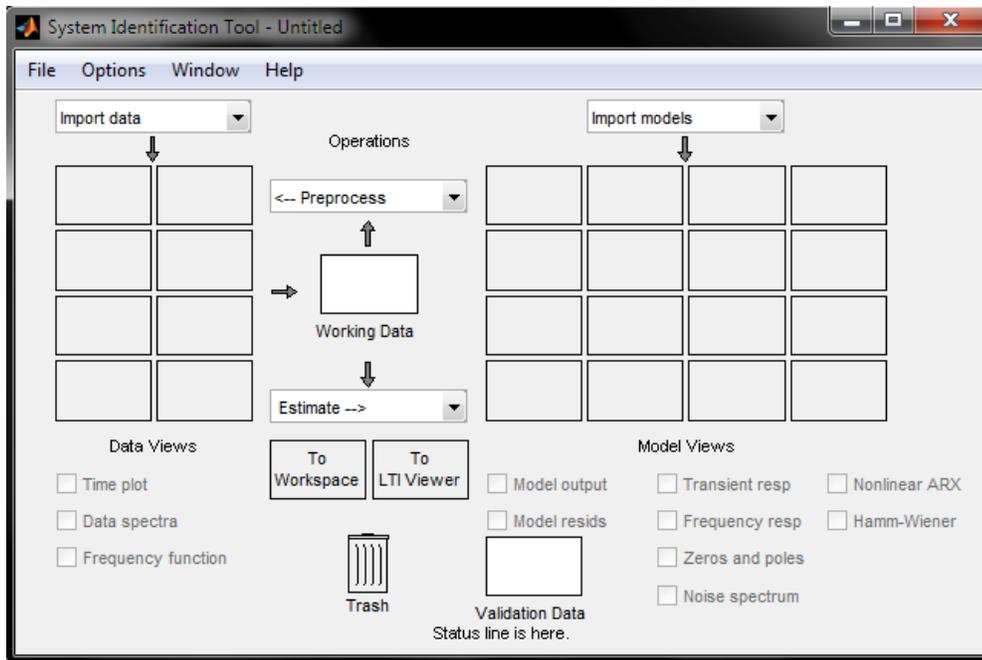
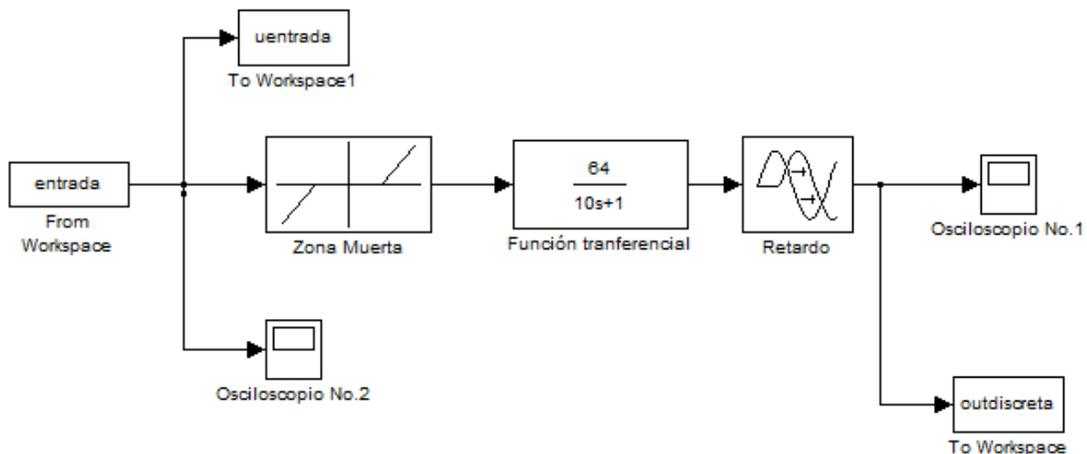


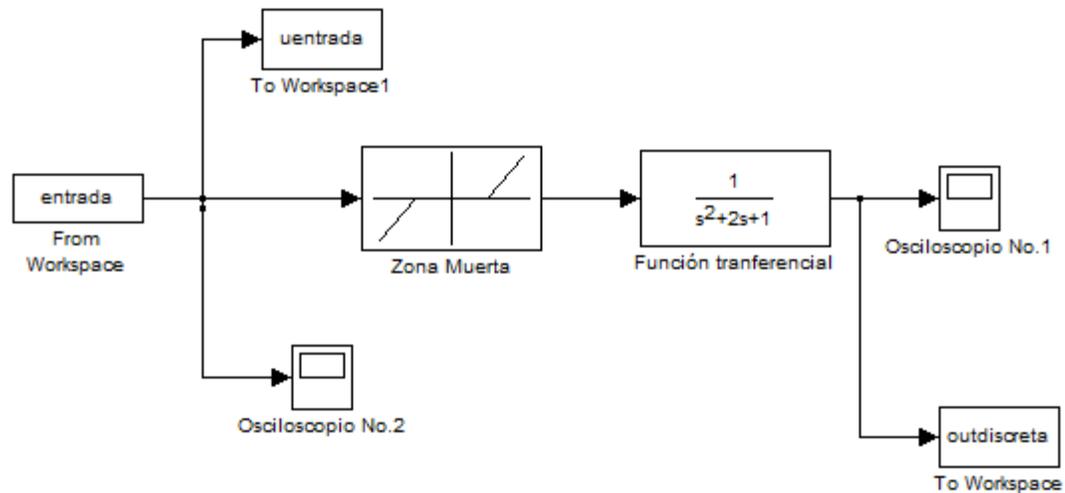
Figura 2.1 Imagen de la ventana de trabajo del Toolbox de Identificación del MatLab® 2010.

2.2 Diseño en Simulink del diagrama en bloques para los distintos sistemas

Uno de los principales pasos a seguir en el proceso de identificación, es el diseño del sistema a tratar, para esto se diseñan los siguientes diagramas en bloques utilizando la herramienta Simulink implementada en MatLab® 2010.



(a) Diseño para el Sistema de Primer Orden



(b) Diseño para el Sistema en Segundo Orden.

Figura 2.2. Diseño en Simulink de los sistemas.

2.3 Elección de la entrada y salida del modelo

Estos datos se obtienen a través de experimentar con el modelo, mediante la excitación del sistema con una señal aleatoria a la entrada del modelo, generada por las siguientes líneas de códigos programados y comentadas en la ventana Editor de MatLab® 2010.

```
u = zeros (10000,1); % definiendo un vector de 10000 elementos
```

```
u (1) = rand;
```

```
for k = 2:10000
```

```
    v= rand;
```

```
    if v > 0.5
```

```
        u (k) = rand;
```

```
    else
```

```
        u (k) = u (k-1);
```

```
    end
```

```
end
```

```
u = 4*u - 2;      % señal resultante
```

```
% en los siguientes gráficos fragmentos de la señal como ejemplo
```

```
stairs (u (1:100)); % plotea la señal seccionalmente continua
```

Como resultado se obtiene a la entrada una serie de gráficas como la que se muestra en la siguiente figura.

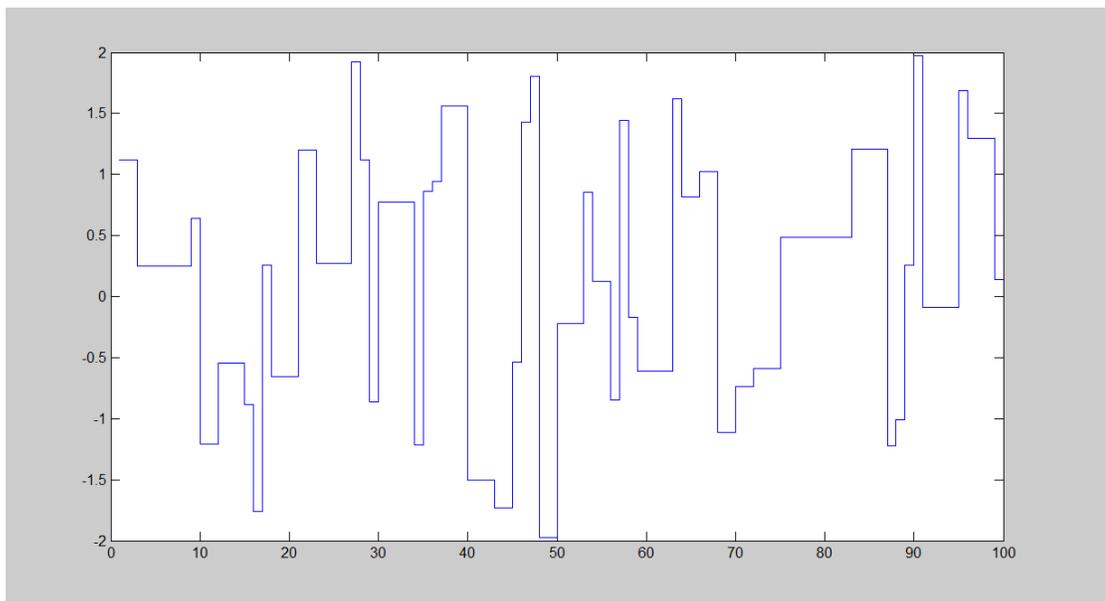


Figura 2.3. Ejemplo de la señal escalonada aleatoria creada.

2.4 Elección de la representación dinámica

Sistemas no lineales a identificar:

a) Sistema de primer orden con retardo.

Forma general.

$$\frac{ke^{-\tau_0 s}}{\tau s + 1}$$

Donde:

$$k = 64$$

$$\tau_0 = 0.5$$

$$\tau = 10$$

b) Sistema de segundo orden.

$$\frac{k}{(\tau_1 s + 1)(\tau_2 s + 1)}$$

Donde:

$$k = 1$$

$$\tau_1 = 1$$

$$\tau_2 = 1$$

En este caso se elige la estructura no lineal con la que se desea trabajar, como se establece en primer capítulo la no linealidad que vamos a utilizar en este trabajo es la Zona Muerta.

Para ello se diseñan los umbrales de trabajo para la Zona Muerta a implementar, donde *Upos* y *Uneg* tomaron los siguientes valores.

Tabla 2.1. Valores de los umbrales de la Zona muerta.

<i>Umbrales</i>	<i>Upos</i>	<i>Uneg</i>
<i>Valores</i>	0	0
25%	0.5	-0.5
50%	1	-1
90%	1.8	-1.8

Hay que decir que la combinación de los cuatro tipos de Zona Muerta con los dos sistemas tanto el de Primer Orden con Retardo como el de Segundo Orden forman ocho sistemas completamente distintos como se muestra en la siguiente figura.



Figura 2.4. Total de sistemas simulados.

Donde:

SPOR es el Sistema de Primer Orden con Retardo y **SSO** es el Sistema de Segundo Orden.

2.5 Registro de datos entrada-salida

Para realizar una correcta identificación, los datos recogidos de la planta deben contener suficiente información sobre esta. Como es sabido, todo proceso de identificación parte de un conjunto de datos de entrada-salida obtenidos de forma experimental a partir del sistema físico que se pretende modelar. Generalmente, sólo se utiliza una parte de esos datos para realizar la identificación del modelo, y los restantes se reservan para realizar la validación del mismo. Los datos suelen encontrarse almacenados en ficheros ASCII, que pueden ser cargados en el Workspace de MatLab® mediante la función *load* para el posterior trabajo con los mismos (Guillén 2006).

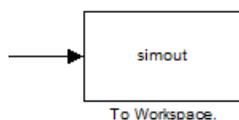


Figura 2.5. Bloque en Simulink de To Workspace.

Todas las funciones del Toolbox de Identificación que requieren como parámetro los datos de entrada-salida, deben recibir dichos datos en una matriz de dos columnas y N filas, siendo N el número de datos (muestras) de entrada-salida registrados. En la primera columna deben aparecer las salidas en sucesivos periodos de muestreo y en la segunda las correspondientes entradas.

2.5.1 Tratamiento previo de los datos entrada-salida

Antes de proceder a realizar la identificación es necesario analizar los datos registrados y decidir si son o no adecuados para el proceso de identificación, o si necesitan algún tipo de tratamiento previo. En caso de que sea necesario, el Toolbox de Identificación proporciona, entre otras, las siguientes funciones para la manipulación de datos como se muestra en la siguiente figura:

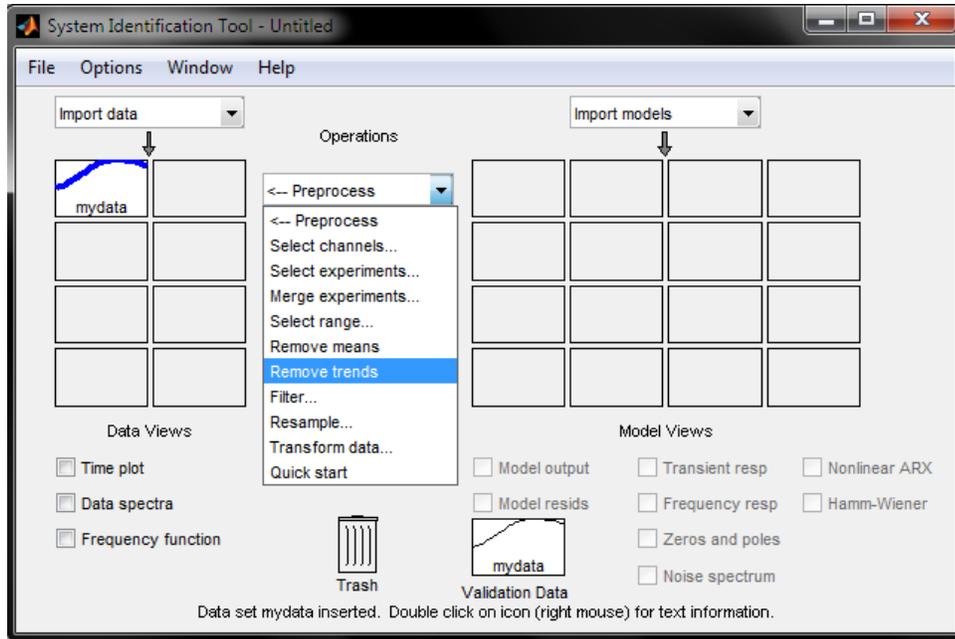


Figura 2.6. Manipulación de la señal mediante la función *dtrend*.

2.6 Elección del orden del modelo

En este paso se aplica el algoritmo para la optimización de los parámetros al mismo tiempo esto nos lleva a dos pasos:

2.6.1 Selección de los modelos

Para este trabajo se utilizan los modelos implementados en la herramienta de identificación de Toolbox del Matlab 2010 mediante la función *ident*.

- Modelo no lineal ARX (NARX).
- Modelo Hammerstein.
- Modelo Wiener.

Hay que decir que no se utiliza el modelo Hammerstein – Wiener, porque no es lógico trabajar con el modelo general que en su estructura incluye dos bloques no lineales mientras que nuestros sistemas nada más presentan una no linealidad, que puede ser tomada tanto en la entrada como en la salida.

2.6.2 Selección de sus parámetros

En los siguientes sub epígrafes se muestran las diferentes configuraciones para los distintos modelos.

2.6.2.1 Modelo no lineal ARX (NARX)

➤ Valores para los regresores.

Tabla 2.2. Valores para los regresores correspondientes a los órdenes.

<i>Regresores</i>	<i>Por defecto</i>	<i>Prueba No.1</i>	<i>Prueba No.2*</i>
<i>na</i>	2	1	3
<i>nb</i>	2	1	3
<i>nk</i>	X	X	X

* *La Identificación con los órdenes de Prueba No.2 es solo para un Sistema de Segundo Orden.*

Para el valor o valores de *nk* se utiliza la opción *Infer Input Delay* con el objetivo de obtener el delay (retardo) de la señal de entrada *u1* a la salida *y1*, como se muestra en la siguiente figura de respuesta al impulso.

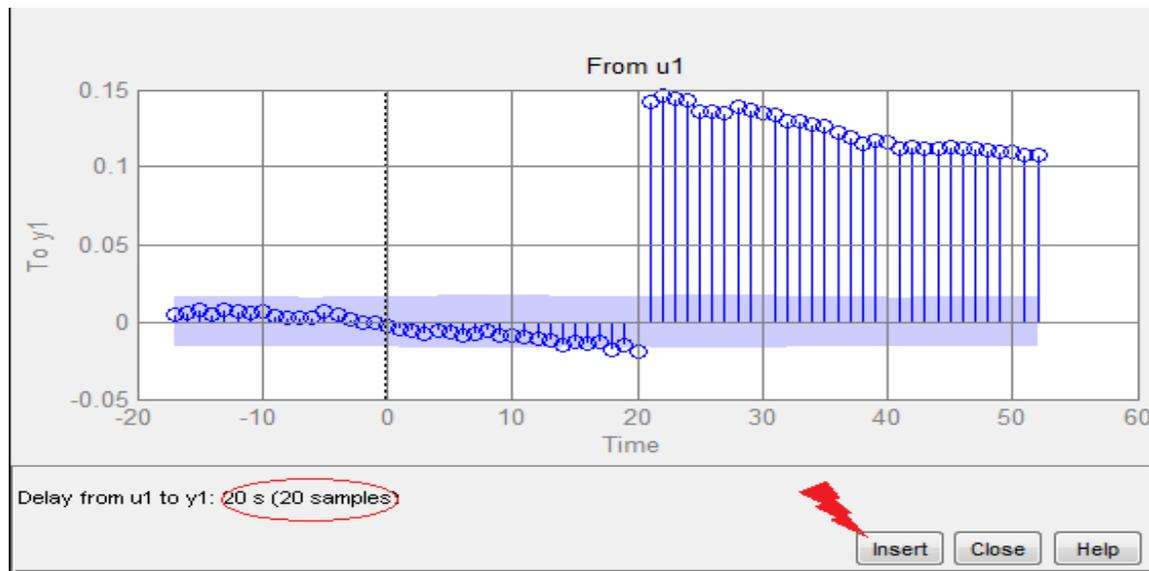


Figura 2.7. Respuesta al Impulso.

En los regresores no lineales se mantiene la estructura por defecto en la primera simulación y para la otra simulación se le propone una segunda estructura, como se ve a continuación:

1) Estructura por defecto.

Entrada: $u1(t-nk), u1(t-(nk+1))$.

Salida: $y1(t-1), y1(t-2)$.

2) Estructura para la Prueba No.1.

Entrada: $u1(t-nk)$.

Salida: $y1(t-1)$.

Estas se muestran en las siguientes figuras:

Standard Regressors	
Regressor	Use in nonlinear block?
$y1(t-1)$	<input checked="" type="checkbox"/>
$y1(t-2)$	<input checked="" type="checkbox"/>
$u1(t-1)$	<input checked="" type="checkbox"/>
$u1(t-2)$	<input checked="" type="checkbox"/>

(a) Por defecto.

Standard Regressors	
Regressor	Use in nonlinear block?
$y1(t-1)$	<input checked="" type="checkbox"/>
$u1(t-1)$	<input checked="" type="checkbox"/>

(b) Prueba No.1.

Figura 2.8. Configuración de los regresores estándares.

➤ El estimador *no linealidad* se establece en los valores de:

Tabla 2.3. Valores de n para el estimador *no linealidad*.

<i>Estimador</i>	<i>Por defecto.</i>	<i>Prueba No.1</i>
<i>Wavelet Network</i>	En selección automática.	-
<i>Tree Partition</i>	En selección automática	-
<i>Sigmoid Network</i>	10	100

2.6.2.2 Modelo Hammerstein

Hay que mencionar que para este modelo se establece, que el estimador (*no linealidad* de entrada) toma la clase “Zona Muerta” y que este estimador se utiliza solo en casos de ser conocida la no linealidad Zona Muerta como se explica en el [Anexo III](#).

Para lograr el diseño del modelo Hammerstein se elimina el bloque de *no linealidad* de salida colocando la opción de *None* en el menú de estimadores como se muestra en la figura.

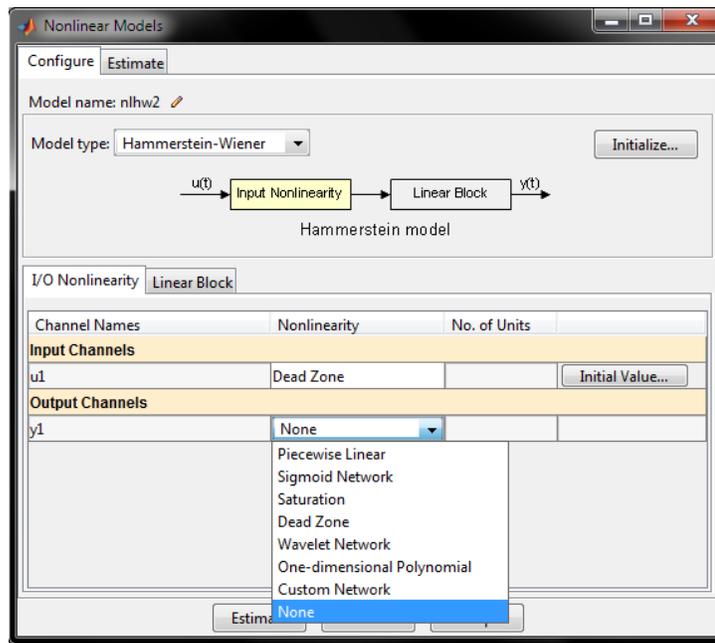


Figura 2.9. Ventana de configuración y de estimación de los modelos no lineales implementados en la herramienta *ident* del Toolbox de Matlab.

Quedando de esta forma el diagrama en Bloques de la figura 1.6 reducido como se muestra en la figura 2.10.

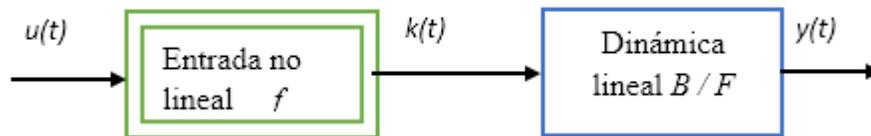


Figura 2.10. Diagrama en Bloques para el Modelo Hammerstein.

➤ Valores para los regresores.

Tabla 2.4. Valores para los regresores correspondientes a los órdenes.

<i>Regresores</i>	<i>Por defecto</i>	<i>Prueba No.1</i>	<i>Prueba No.2*</i>
<i>nf</i>	2	1	3
<i>nb</i>	2	1	3
<i>nk</i>	X	X	X

* La Identificación con los órdenes de Prueba No.2 es solo para un Sistema de Segundo Orden.

Al igual que para el modelo anterior, en la obtención del valor de nk se utiliza la opción *Infer Input Delay* con el objetivo de obtener el retardo de la señal de entrada $u1$ a la salida $y1$.

Para los regresores no lineales se mantiene la estructura por defecto en la primera simulación y para la otra simulación se le propone una segunda estructura, como se ve a continuación:

1) Estructura por defecto.

$B= 2$ Ceros.

$F= 2$ Polos.

2) Estructura para la Prueba No.1.

$B= 1$ Cero.

$F= 1$ Polo.

Donde:

B es el orden del numerador y F es el orden del denominador.

➤ El estimador *no linealidad* se establece en los valores de:

Para el estimador se selecciona la no linealidad Zona Muerta (Dead Zone) en el canal de entrada $u1$ como se muestra en la figura 2.11 quedando de la siguiente forma.

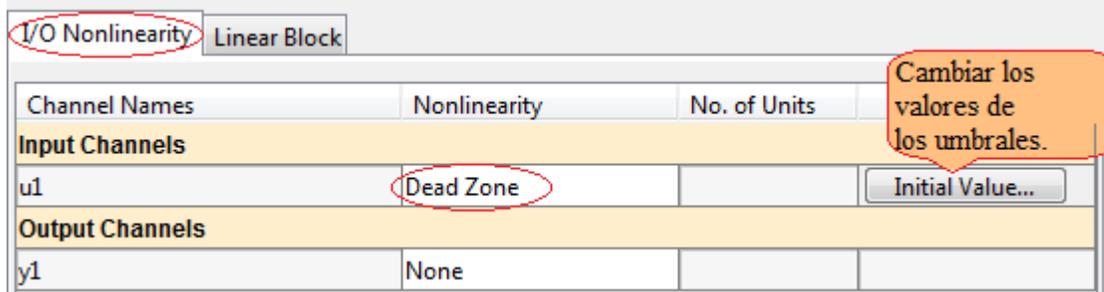


Figura 2.11. Configuración final para el estimador *no linealidad*.

2.6.2.3 Modelo Wiener

Hay que mencionar que para este modelo se establece que el estimador (*no linealidad* de salida) toma la clase “Zona Muerta”. Decir que este estimador se utiliza solo en casos de ser conocida la no linealidad Zona Muerta como se explica en el [Anexo III](#).

Para la obtención del diseño del modelo Wiener, el bloque de *no linealidad* de entrada se coloca en la opción de *None* en el menú de estimadores como se muestra en la figura 2.12.

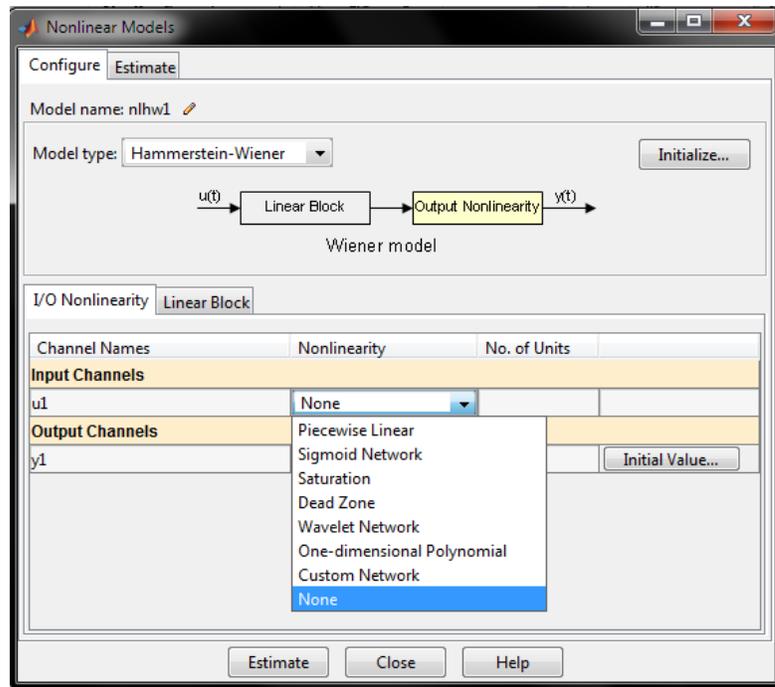


Figura 2.12. Ventana de configuración y de estimación de los modelos no lineales implementados en la herramienta *ident* del Toolbox de Matlab.

Quedando de esta forma el diagrama en Bloques de la figura 1.6 reducido como se muestra en la figura 2.13.

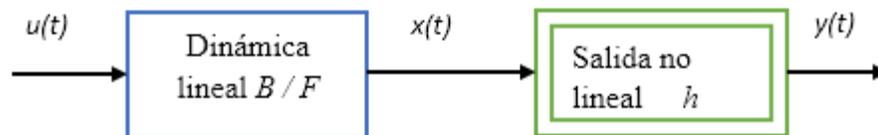


Figura 2.13. Diagrama en Bloques para el Modelo Wiener.

➤ Valores para los regresores.

Tabla 2.5. Valores para los regresores correspondientes a los órdenes.

<i>Regresores</i>	<i>Por defecto</i>	<i>Prueba No.1</i>	<i>Prueba No.2*</i>
<i>nf</i>	2	1	3
<i>nb</i>	2	1	3
<i>nk</i>	X	X	X

* La Identificación con los órdenes de Prueba No.2 es solo para un Sistema de Segundo Orden.

Al igual que para el modelo anterior, para hallar el valor de nk , se utilizó la opción *Infer Input Delay* con el objetivo de obtener el delay de la señal de entrada $u1$ a la salida $y1$.

Para los regresores no lineales se mantiene la estructura por defecto en la primera simulación y para la otra simulación se le propone una segunda estructura, como se ve a continuación:

1) Estructura por defecto.

$B= 2$ Ceros.

$F= 2$ Polos.

2) Estructura para la Prueba No.1.

$B= 1$ Cero.

$F= 1$ Polo.

Donde:

B es el orden del numerador y F es el orden del denominador.

➤ El estimador *no linealidad* se establece en los valores de:

Para el estimador se selecciona la no linealidad Zona Muerta (Dead Zone) en el canal de salida $y1$ como se muestra en la figura 2.14 quedando de la siguiente forma.

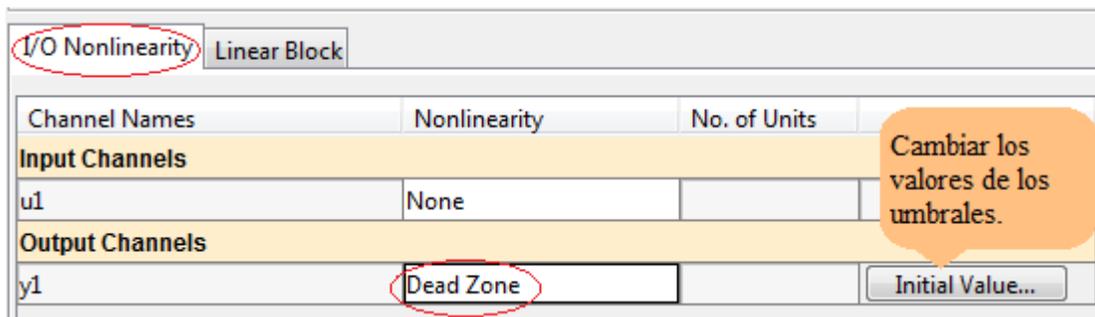


Figura 2.14. Configuración final para el estimador *no linealidad*.

2.7 Validación de los modelos

Por último, es necesario demostrar si los modelos estimados representan la dinámica de los sistemas identificados para los fines deseados. A esto se le llama validación del modelo, existen formas de validar un modelo estimado y de esta manera tener una mejor confianza en él. La herramienta de validación más utilizada es mediante la simulación haciendo un análisis de residuos, respuesta en frecuencia, respuesta temporal, entre otras, en este trabajo se usa la validación en el dominio del tiempo.

La validación en el dominio del tiempo consiste en observar la respuesta de los modelos obtenidos y del sistema real ante las entradas escalón e impulso.

Para ellos se divide los datos de entrada-salida a analizar de la siguiente forma.

Para la identificación se toman los datos del 1 al 2501, y para la validación se toman los datos del 2502 a al 3901 como se muestra en la siguiente figura.

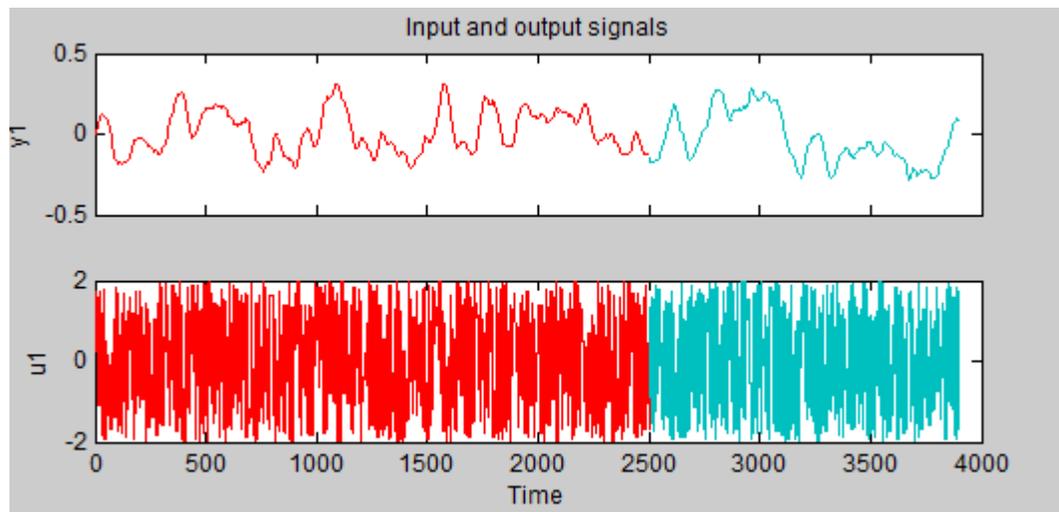


Figura 2.15. Muestra de los datos dedicados a la identificación y a la validación.

Donde:

La línea de color rojo es la muestra dedicada a la identificación y la línea de color azul es la porción de la muestra dedicada a la validación.

Decir que esta manera de elección de los datos para identificar y validar se cumple para todas las simulaciones.

Por otra parte, cada modelo se valida con respecto a sus objetivos. No se puede decir que un modelo válido para un propósito lo tenga que ser necesariamente para otros. Por otro lado, la idea de la simulación es construir modelos sencillos para objetivos concretos, lo que aleja de la idea de validez general. La realidad es el único “modelo” válido de forma general (Banks, Carson et al. 2002).

2.8 Algoritmos de optimización

Se optimizan los pesos sinápticos mediante la selección automática del algoritmo, con el objetivo de encontrar los mejores pesos que ajustan la respuesta del modelo a los datos de entrada-salida como se muestra en la siguiente figura.

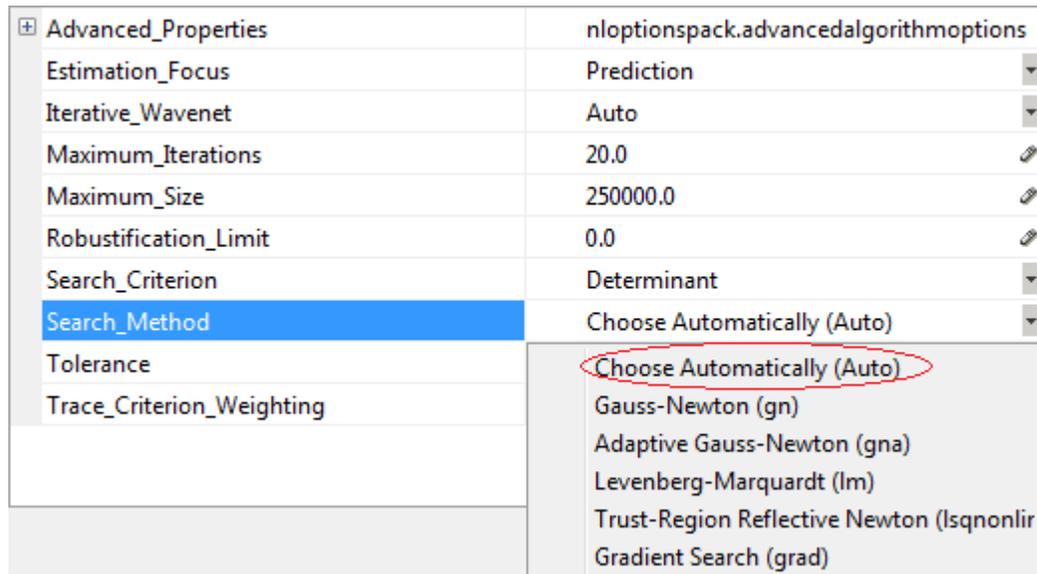


Figura 2.16. Configuración de los algoritmos de optimización.

2.9 Consideraciones finales del capítulo

- La unión de los dos sistemas con los varios tipos de Zona Muerta ofrece como resultado, ocho sistemas distintos, lo cual permite una mayor caracterización de los procesos.
- El diseño de los modelos para varios órdenes y estimadores en el caso del modelo NARX, logra un incremento de resultados necesarios a la hora de comparar los modelos no lineales.

CAPÍTULO 3. RESULTADOS Y ANÁLISIS DE LAS SIMULACIONES

Este capítulo incluye y tabula los resultados de las simulaciones diseñadas en el Capítulo 2, en él se establece una comparación entre dichos resultados con el objetivo de dar respuesta a la problemática presentada en la introducción del mismo, para ello se crean dos interrogantes con el fin de obtener al cierre del capítulo, un criterio único con respecto al tema tratado.

Por último se realiza una valoración económica del trabajo atendiendo a sus principales aspectos.

3.1 Resultados de la simulación de los modelos no lineales

Para la comparación de los resultados se tomó el siguiente convenio en la clasificación de los FIT (por ciento de ajuste) con el fin de establecer un valor desde el cual se podría decir que tan bueno es el por ciento de ajuste de los modelos creados con respecto a los sistemas identificados.

Por otro lado se establecen dos preguntas para dar respuesta al objetivo del trabajo, que no es más que obtener el mejor modelo o método no lineal para identificar un sistema con Zona Muerta.

- ¿Qué tan bueno es el modelo?

Donde tenemos los siguientes rangos:

Malo: $FIT\% < 80$

Bueno: $80 \leq FIT\% \leq 90$

Excelente: $FIT\% > 90$

- ¿Cuál es el modelo no lineal con mejor comportamiento ante los sistemas identificados?

3.2 Sistema de Primer Orden con Retardo

El análisis de este sistema se divide en cuatro sistemas diferente como se explica en el capítulo anterior, los cuales proporcionan cuatro juegos de datos entrada – salida. A continuación se muestran los resultados para los tres modelos implementados, dando respuesta a la primera pregunta planteada en el epígrafe anterior.

3.2.1 Zona Muerta al 0%

Tabla 3.1. Resultados de los modelos NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	1	1	20	1	51.13
	2	2	20	1	100
Tree Partition	1	1	20	511	31.91
	2	2	20	255	99.53
Sigmoid Network	1	1	20	10	33.38
	1	1	20	100	37.01
	2	2	20	10	100
	2	2	20	100	100

Tabla 3.2. Resultado del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	100
	2	2	20	-	100

Tabla 3.3. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	100
	2	2	20	-	100

Para este sistema los modelos que se destacan por su comportamiento son:

El modelo NARX con el orden $n_a=2$, $n_b=2$, $n_k=20$ y los tres estimadores.

El modelo Hammerstein con sus dos configuraciones, al igual que el modelo Wiener. En todos los casos obteniéndose un excelente por ciento de ajuste a la curva.

3.2.2 Zona Muerta al 25%

Tabla 3.4. Resultados de los modelos NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT %</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	1	1	21	118	NAN*
	2	2	21	58	77.65
Tree Partition	1	1	21	511	71.14
	2	2	21	255	80.15
Sigmoid Network	1	1	21	10	70
	1	1	21	100	96.58
	2	2	21	10	62.75
	2	2	21	100	89.24

*NAN término utilizado para los casos que no se ajustan en nada a la curva.

Tabla 3.5. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	100
	2	2	21	-	100

Tabla 3.6. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	65.17
	2	2	21	-	80.61

En el sistema los modelos de mejor comportamiento son:

El modelo Hammerstein, para sus dos órdenes simulados con un excelente por ciento de ajuste, también con un excelente FIT tenemos al modelo NARX con el estimador Sigmoid Network, orden $n_a = 1$, $n_b = 1$ y $n_k = 21$, y 100 unidades.

3.2.3 Zona Muerta al 50%

Tabla 3.7. Resultados del modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT %</i>
	<i>n_a</i>	<i>n_b</i>	<i>n_k</i>		
Wavelet Network	1	1	21	122	95
	2	2	21	57	82.21
Tree Partition	1	1	21	511	93.58
	2	2	21	255	78.34

Sigmoid Network	1	1	21	10	59.92
	1	1	21	100	92.13
	2	2	21	10	88.42
	2	2	21	100	94.62

Tabla 3.8. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	100
	2	2	21	-	100

Tabla 3.9. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	15.31
	2	2	21	-	38.97

Para este sistema los modelos que más se acercaron al comportamiento del sistema a identificar son:

El modelo NARX que con las siguientes configuraciones obtuvo excelentes FIT.

Estimador Wavelet Network, orden $n_a = 1$, $n_b = 1$, $n_k = 21$ y 122 unidades.

Estimador Tree Partition, orden $n_a = 1$, $n_b = 1$, $n_k = 21$ y 511 unidades.

Estimador Sigmoid Network, orden $n_a = 1$, $n_b = 1$, $n_k = 21$ y 100 unidades.

Estimador Sigmoid Network, orden $n_a = 2$, $n_b = 2$, $n_k = 21$ y 100 unidades.

El modelo Hammerstein con las siguientes configuraciones obtuvo el mejor FIT para este sistema con un 100% de ajuste donde, $n_f = 1$, $n_f = 2$, $n_b = 1$, $n_b = 2$ y $n_k = 21$.

3.2.4 Zona Muerta al 90%

Tabla 3.10. Resultados del modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT %</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	1	1	21	121	3.12
	2	2	21	57	-198.3
Tree Partition	1	1	21	511	31.68
	2	2	21	255	-18.64
Sigmoid Network	1	1	21	10	-99.1
	1	1	21	100	-504.7
	2	2	21	10	-76.91
	2	2	21	100	NAN*

* NAN término utilizado para los casos que no se ajustan en nada a la curva.

Al no obtener ningún FIT apropiado para este sistema provoca que el modelo NARX quede descartado para la identificación de un Sistema de Primer Orden con Retardo con una Zona Muerta al 90%.

Tabla 3.11. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	100
	2	2	21	-	100

Tabla 3.12. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	1	1	21	-	-121.6
	2	2	21	-	-121.6

Al terminar la simulación de dicho sistema la estructura de mejor comportamiento es el modelo Hammerstein para sus dos configuraciones, reportando como resultado un excelente FIT = 100%.

3.3 Sistema de Segundo Orden

El sistema identificado a continuación al igual que con el anterior se divide en cuatro sistemas diferentes, lo cual logra un mayor aprovechamiento de los datos a la hora de establecer una comparación para obtener el comportamiento de los modelos no lineales, y el indicado en los diferentes casos.

3.3.1 Zona Muerta al 0%

Tabla 3.13. Resultados del modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	3	3	1	1	100
	2	2	1	1	100
Tree Partition	3	3	1	255	13.25
	2	2	1	255	-5.084
Sigmoid Network	3	3	1	10	100
	3	3	1	100	100

	2	2	1	10	100
	2	2	1	100	100

Tabla 3.14. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	0	-	100
	2	2	1	-	100

Tabla 3.15. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	0	-	100
	2	2	1	-	100

Hay que decir que para este sistema todos los modelos excepto el NARX con el estimador Tree Partition mostraron un FIT = 100% lo cual da una caracterización excelente del sistema a identificar.

3.3.2 Zona Muerta al 25%

Tabla 3.16. Resultados con el modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	3	3	1	14	69.43
	2	2	1	38	77.56
Tree Partition	3	3	1	255	11.77

	2	2	1	255	6.902
Sigmoid Network	3	3	1	10	NAN
	3	3	1	100	-102
	2	2	1	10	79.76
	2	2	1	100	-7822

* NAN término utilizado para los casos que no se ajustan en nada a la curva.

Tabla 3.17. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	100
	2	2	1	-	100

Tabla 3.18. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	-22.28
	2	2	1	-	-22.28

Para este sistema se tiene que:

Tanto el modelo no lineal NARX como el Wiener no logran una buena caracterización. Mientras que el modelo no lineal Hammerstein obtiene un FIT = 100%.

3.3.3 Zona Muerta al 50%

Tabla 3.19. Resultados del modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	3	3	1	15	65.48
	2	2	1	43	58.26
Tree Partition	3	3	1	255	5.331
	2	2	1	255	1.914
Sigmoid Network	3	3	1	10	-520.7
	3	3	1	100	-927.2
	2	2	1	10	30.64
	2	2	1	100	70.37

Tabla 3.20. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	100
	2	2	1	-	100

Tabla 3.21. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	-0.8106
	2	2	1	-	-0.8106

Al igual que para el sistema anterior el único modelo no lineal que logra una buena caracterización del sistema a identificar, es el Hammerstein para sus dos configuraciones, en el cual la variación de sus órdenes no causa una diferencia apreciable, obteniendo para las dos un FIT = 100%.

3.3.4 Zona Muerta al 90%

Tabla 3.22. Resultados del modelo NARX.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>na</i>	<i>nb</i>	<i>nk</i>		
Wavelet Network	3	3	1	13	-2.475
	2	2	1	44	7.211
Tree Partition	3	3	1	255	-39.9
	2	2	1	255	-40.34
Sigmoid Network	3	3	1	10	-0.4434
	3	3	1	100	8.154
	2	2	1	10	-12.25
	2	2	1	100	0.5606

Tabla 3.23. Resultados del modelo Hammerstein.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	100
	2	2	1	-	100

Tabla 3.24. Resultados del modelo Wiener.

<i>Estimador</i>	<i>Orden del modelo</i>			<i>Unidad</i>	<i>FIT % Curva</i>
	<i>nf</i>	<i>nb</i>	<i>nk</i>		
Dead Zone	3	3	1	-	-6.396
	2	2	1	-	-6.396

Para este sistema vuelve a resaltar el modelo no lineal Hammerstein con un FIT = 100% en sus dos configuraciones propuestas.

Tanto el modelo no lineal NARX como el Wiener no producen una buena caracterización del sistema.

3.4 ¿Cuál es el modelo no lineal con mejor comportamiento ante los sistemas identificados?

Con el análisis de los resultados de las noventa y seis simulaciones, se logró obtener de forma cuantitativa el conocimiento sobre el comportamiento de estos modelos tratados frente a los sistemas a identificar, permitiendo conocer el modelo que mejor logra la caracterización de estos sistemas tratados.

El modelo no lineal Hammerstein con todas las configuraciones propuestas para él, logra un excelente por ciento de ajuste (FIT = 100%) en todos los sistemas identificados.

Lo cual afirma que es el modelo no lineal a utilizar para la Identificación no Lineal de un Sistema con Zona Muerta, por otro lado se prueba la hipótesis planteada en las consideraciones finales del Capítulo 1.

3.5 Valoración económica.

Un aspecto fundamental en la realización del proyecto es la valoración económica, este abarca tanto los gastos que generó el desarrollo, como los beneficios que traerían para la entidad que disponga de la investigación realizada hasta el momento.

Los resultados de este trabajo de diploma contribuyen a posibilitar otras tareas de investigación en el área del desarrollo de los modelos para la identificación, por tanto es un trabajo enmarcado en investigaciones básicas, que contribuye al desarrollo de herramientas computacionales a emplear en otras tareas científicas. Por lo anterior, el costo de este proyecto de diploma es gasto no reintegrable y a consideración del autor se toma como despreciable.

Nuevos horizontes de la investigación científica se abren con estas nuevas capacidades. El impacto es directo en todas las ramas del conocimiento y la investigación científica, sea en investigaciones básicas o en aplicadas. Los resultados a alcanzar constituyen valiosas herramientas para los centros de investigación, sobre todo los relacionados con la biotecnología, la industria, la energía y con el medio ambiente en cualquiera de sus modalidades.

El desarrollo de este trabajo no genera beneficios económicos de forma directa. Está condicionado a aumentar la productividad de los investigadores, que emplearán los resultados de este en investigaciones de carácter básico.

3.6 Consideraciones finales del capítulo

Una vez implementado los modelos y analizados los resultados pudimos arribar a las siguientes conclusiones:

- Se logra mostrar de manera resumida, el comportamiento de los modelos no lineales utilizados para la identificación de los sistemas tratados, mediante la tabulación de los resultados de las simulaciones. Lo cual da respuesta a la primera interrogante planteada en el principio del capítulo.
- Con la caracterización en cuanto a la aplicabilidad y el comportamiento de los modelos no lineales utilizados se logró obtener el método que más se acercaba a los modelos de los sistemas tratados. Dando así respuesta a la segunda interrogante planteada en el capítulo.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

Con el empleo de los modelos o métodos no lineales para identificar sistemas que presentan zona muerta para el cual se tomó varias de sus formas se obtuvo los siguientes resultados o conclusiones:

- Se emplearon las técnicas de identificación no lineal, tales como, NARX, funciones de Wiener y Hammerstein en sistemas que presenta zona muerta en varias de sus formas, obteniendo muy buenos resultados en cuanto al por ciento de ajuste (FIT).
- La tabulación de los datos de las simulaciones permitió, un mayor análisis a la hora de comparar los resultados arrojados de cada técnica empleada en la identificación logrando así, un mejor estudio del comportamiento de dichos modelos.
- Se pudo comprobar la hipótesis planteada con los resultados arrojados por las simulaciones, resultando cierto dicho planteamiento.
- Al terminar la caracterización de los comportamientos de los métodos implementados, se obtuvo el mejor modelo no lineal para identificar sistemas que presenten una zona muerta específica, en este caso los sistemas estudiados.

Recomendaciones

Dentro del contexto de identificación de sistemas no lineales cabe mencionar que durante el desarrollo de este trabajo de tesis se encontraron temas relacionados bastante interesantes que se pueden abordar y de esta manera enriquecer el acervo dentro de la comunidad de control automático tanto en nuestro centro como en otras instituciones. Tomando, como referencia este trabajo se proponen los siguientes temas:

- Hacer la programación e implementación de las estructuras NARX y Hammerstein-Wiener a sistemas de múltiples entradas y una sola salida (MISO), sistemas de una entrada y múltiples salidas (SIMO) y a sistemas de múltiples entradas y salidas (MIMO) bajo el enfoque de entrada-salida ya que en este trabajo solo se realizó para sistemas de una entrada una salida (SISO).
- Programar e implementar una aplicación que permita el análisis de los principales parámetros de los modelos obtenidos con el objetivo de sustituir la función del ingeniero al seleccionar el mejor modelo entre los identificados.
- Identificación de sistemas no lineales mediante las estructuras NARX y Hammerstein-Wiener para sistemas que presenten otros tipos de no linealidades más complejas o sistemas con un mayor grado de complejidad.
- Identificación de sistemas no lineales mediante las estructuras NARX y Hammerstein-Wiener utilizando otro estimador no lineal diferente a los utilizados en este trabajo como por ejemplo: Custom Network, Saturation, entre otros; con el fin de compararlos y poder determinar cuál de todos estos es mejor para cada estructura.

REFERENCIAS BIBLIOGRÁFICAS

Abd-Elrady, E. and L. Gan (2008). Identification of Hammerstein and Wiener models using spectral magnitude matching. Proceedings of the IFAC World Congress on Automatic Control.

Acoltzi, U. F. (2011). Identificación de sistemas no lineales mediante las estructuras NARX y Hammerstein-Wiene. Centro Nacional de Investigación y Desarrollo Tecnológico, Departamento de Ingeniería Electrónica. Cuernavaca.

Banks, J., et al. (2002). "Verificación y Validación."

Cubero, R. G. (1993). CONTRIBUCIÓN A LA IDENTIFICACIÓN DE SISTEMAS DINÁMICOS MEDIANTE MÉTODOS CONEXIONISTAS. AUTOMATIZACIÓN AVANZADA Y ROBÓTICA, UNIVERSIDAD POLITÉCNICA DE CATALUÑA.

dos Santos Coelho, L. and M. W. Pessôa (2009). "Nonlinear model identification of an experimental ball-and-tube system using a genetic programming approach." Mechanical Systems and Signal Processing **23**(5): 1434-1446.

Hagan, M. T. and M. B. Menhaj (1994). "Training feedforward networks with the Marquardt algorithm." Neural Networks, IEEE Transactions on **5**(6): 989-993.

Janczak, A. (2004). Identification of nonlinear systems using neural networks and polynomial models: a block-oriented approach, Springer Science & Business Media.

Juditsky, A., et al. (1995). "Nonlinear black-box models in system identification: Mathematical foundations." Automatica **31**(12): 1725-1750.

Kara, T. and I. Eker (2004). "Nonlinear modeling and identification of a DC motor for bidirectional operation with real time experiments." Energy Conversion and Management **45**(7): 1087-1106.

Lennart, L. (2014). System Identification Toolbox™
User's Guide, The MathWorks.

Ljung, L. (1997). Nonlinear Black Box Models in System Identification. Proceedings of the 1997 IFAC International Symposium on Advanced Control of Chemical Processes.

Ljung, L. (2007). "Identification of nonlinear systems."

Ljung, L. (2010). "Perspectives on system identification." Annual Reviews in Control **34**(1): 1-12.

López, E. (2007). Identificación de sistemas en lazo cerrado con estructura tipo CLOE, MS thesis, Dept. Electron. Eng., Centro Nacional de Investigación y Desarrollo., Morelos, Mexico.

Murray-Smith, R. and T. Johansen (1997). Multiple model approaches to nonlinear modelling and control, CRC press.

Narendra, K. S. and K. Parthasarathy (1990). "Identification and control of dynamical systems using neural networks." Neural Networks, IEEE Transactions on **1**(1): 4-27.

Nelles, O. (2001). Nonlinear system identification. , Springer, Berlin.

Rubio, R. E., et al. (2007). "Modelado, Identificación y Control de Actuadores Lineales Electroneumáticos. Aplicación en Plataforma de Dos Grados de Libertad." Revista Iberoamericana de Automática e Informática Industrial RIAI **4**(4): 58-69.

Sjöberg, J., et al. (1995). "Nonlinear black-box modeling in system identification: a unified overview." Automatica **31**(12): 1691-1724.

Thaler, G. and M. Pastel (1962). Analysis and Design of Non-linear Control Systems, McGraw-Hill, New York.

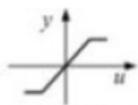
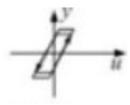
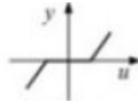
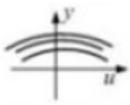
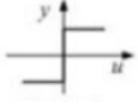
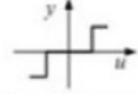
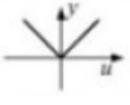
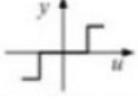
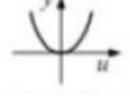
Ugalde, H. M. R. (2008). "Identificación de sistemas utilizando redes neuronales." Departamento de Electrónica, Maestría, Centro Nacional de Investigación y Desarrollo Tecnológico, Cuernavaca, Morelos.

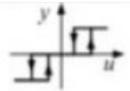
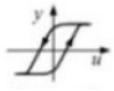
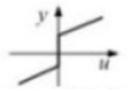
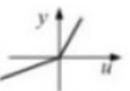
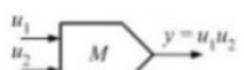
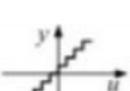
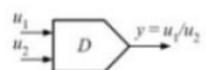
Vörös, J. (2004). "An iterative method for Hammerstein-Wiener systems parameter identification." Journal of electrical engineering **55**(11-12): 328-331.

ANEXOS

Anexo I No linealidades más comunes.

Diagrama de las no linealidades más comunes.

<i>No.</i>	Símbolo y nombre.	<i>No.</i>	Símbolo y nombre.
1	 Saturación	11	 Reacción (para engranajes)
2	 Zona Muerta	12	 Curvas características
3	 Relé ideal	13	 Ganancia no lineal
4	 Relé con Histéresis	14	 Rectificador
5	 Relé con Zona Muerta	15	 Función cuadrática

6		16	
	Relé con Zona Muerta e Histéresis		Linealidad general
7		17	
	Histéresis		Fricción de Coulomb
8		18	
	Lineal por tramos		Dirección dependiente de la ganancia
9		19	
	Constante por tramos		Multiplicación
10		20	
	Cuantización		División

Anexo II Estimadores para NARX.

Estimador	clase	Estructura	Comentarios
Red Wavelet (por defecto)	wavenet	$g(x) = \sum_{k=1}^n \alpha_n k(B_k(x - \gamma_k))$ <p>Donde $k(s)$ es la Función Wavelet.</p>	Por defecto el algoritmo de estimación determina el número de unidades n automáticamente.
Red de una capa sigmoideo	sigmoidnet	$g(x) = \sum_{k=1}^n \alpha_n k(B_k(x - \gamma_k))$ <p>Donde $k(s) = (e^s + 1)^{-1}$ es la Función sigmoidea. B_k es un vector de fila de tal manera que $B_k(x - \gamma_k)$ es un escalar.</p>	Por defecto el número de unidades n es 10.
Árbol de Partición	treepartition	Función lineal a trozos más particiones del espacio definido por un regresor de árbol binario.	El algoritmo de estimación determina el número de unidades automáticamente. Trate de usar árbol de particiones para el modelado de datos recogido bajo un rango de condiciones de funcionamiento.
F es lineal en x	linear	Este estimador produce un modelo que es similar al modelo ARX lineal, pero ofrece la flexibilidad adicional de especificar los regresores personalizados.	Se utiliza para especificar regresores personalizados como el estimador no linealidad y excluir a un mapeo de la función no linealidad

Red neuronal multicapa	neuralnet	Utiliza como un objeto de red creado mediante el software de red neuronal de la caja de herramientas.(Neural Network Toolbox™)	
Red de Costumbre (usuario-definido)	customnet	Similar a una red sigmoidea pero te especifica $k(s)$.	(Para un uso avanzado) Usa la función que se le especifique.

Anexo III Estimadores para el Modelo Hammerstein- Wiener.

Estimador	clase	Estructura	Comentarios
<i>Lineal por tramos.</i>	pwlinear	Una función lineal por tramos parametrizada por ubicaciones de punto de interrupción.	Por defecto el número del punto de ruptura es 10.
<i>Red de una capa sigmoidea</i>	sigmoidnet	$g(x) = \sum_{k=1}^n \alpha_n k(B_k(x - \gamma_k))$ <p>Donde $k(s) = (e^s + 1)^{-1}$ es la Función sigmoidea. B_k es un vector de fila de tal manera que $B_k(x - \gamma_k)$ es un escalar.</p>	Por defecto el número de unidades n es 10.
<i>Red Wavelet (por defecto)</i>	wavenet	$g(x) = \sum_{k=1}^n \alpha_n k(B_k(x - \gamma_k))$ <p>Donde $k(s)$ es la Función Wavelet.</p>	Por defecto, el algoritmo de estimación determina el número de unidades n automáticamente.
<i>Saturación</i>	saturation	Parametrizar límites duros en la señal como el valor de límite de saturación superior e inferior.	Se utiliza para modelar los efectos de saturación conocidos en amplitudes de señal.
<i>Zona Muerta</i>	deadzone	Parametrizar zonas muertas en señales como la duración de la respuesta cero.	Se utiliza para modelar zonas muertas conocidas En amplitudes de la señal.
<i>Polinomio unidimensional</i>	poly1d	Polinomio de una sola variable del grado que se especifique.	Por defecto, el polinomio es de grado 1.

<i>Ganancia unitaria</i>	unitgain	<p>Excluye la no linealidad de entrada o salida de la estructura del modelo para lograr una configuración Wiener o Hammerstein, respectivamente.</p> <p>Nota: Sin incluir la no linealidad tanto de entrada como de salida reduce la estructura Hammerstein -Wiener a una función de transferencia lineal.</p>	<p>Útil para la configuración múltiples entradas , múltiples salidas (MIMO) modelos para excluir no linealidades de de entrada específica y canales de salida.</p>
<i>Red de Costumbre (usuario-definido)</i>	customnet	<p>Similar a una red sigmoidea pero te especifica $k(s)$.</p>	<p>(Para un uso avanzado)</p> <p>Usa la función que se le especifique.</p>