

**INSTITUTO TECNOLOGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY
CAMPUS MONTERREY**

**DIVISION DE COMPUTACION, INFORMACION Y
COMUNICACIONES**

**PROGRAMA DE GRADUADOS EN
COMPUTACION, INFORMACION Y COMUNICACIONES**



**MODELACION DE UN ALIMENTADOR DE VIDRIO
UTILIZANDO UNA RED NEURONAL DE RETROPROPAGACION**

TESIS

**PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL
GRADO ACADEMICO DE:**

**MAESTRO EN CIENCIAS
ESPECIALIDAD EN INGENIERIA DE CONTROL**

ING. NICOLAS FLORES CARDONA

MAYO, 1999

**INSTITUTO TECNOLOGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY
CAMPUS MONTERREY**

**DIVISION DE COMPUTACION, INFORMACION Y
COMUNICACIONES**

**PROGRAMA DE GRADUADOS EN
COMPUTACION, INFORMACION Y COMUNICACIONES**

**MODELACION DE UN ALIMENTADOR DE VIDRIO
UTILIZANDO UNA RED NEURONAL DE RETROPROPAGACION**

T E S I S

**PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL
GRADO ACADEMICO DE:**

**MAESTRO EN CIENCIAS
ESPECIALIDAD EN INGENIERIA DE CONTROL**

REALIZADA POR:

ING. NICOLAS FLORES CARDONA

MONTERREY, N.L.

MAYO, 1999

**INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY
CAMPUS MONTERREY**

DIVISION DE COMPUTACION, INFORMACION Y COMUNICACIONES

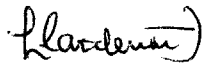
PROGRAMA DE GRADUADOS EN
COMPUTACION, INFORMACION Y COMUNICACIONES

Los miembros del comité de tesis recomendamos que la presente Tesis realizada por el **Ing. Nicolás Flores Cardona**, sea aceptada como requisito parcial para obtener el grado académico de **Maestro en Ciencias con Especialidad en Ingeniería de Control**.

Comité de Tesis:



Rogelio Soto Rodríguez, Ph. D.
Asesor

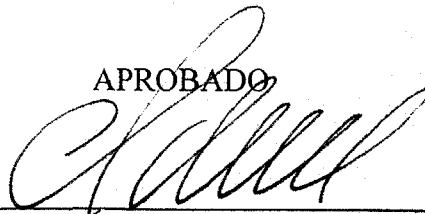


Luis Cárdenas Franco, M. Sc.
Sinodal



Alberto Cavazos González, Ph. D.
Sinodal

APROBADO



Carlos Scheel Mayenberger, Ph.D.
Director del Programa de Graduados en
Computación, Información y Comunicaciones

A mi esposa Cristina y mi hija Claudia Paola

A mis padres Miguel Angel y María del Carmen

Agradecimientos

Quiero agradecer al Dr. Rogelio Soto, asesor de esta tesis, al M. Sc. Luis Cárdenas y al Dr. Alberto Cavazos, sinodales de la misma, por todos sus comentarios y sugerencias acerca del desarrollo de esta tesis.

A mi esposa, por el ánimo, paciencia y apoyo que me otorgó durante el desarrollo de esta tesis.

A mis compañeros de trabajo, en especial al Ing. José Luis Carvajal, al Ing. Iván Solís y al Ing. Mario González por sus comentarios y apoyo en la recolección de datos.

Al Grupo Vitro por las facilidades económicas y materiales otorgadas para la realización de esta tesis.

Nicolás Flores Cardona

*Instituto Tecnológico y de Estudios Superiores de Monterrey
Mayo de 1999*

MODELACION DE UN ALIMENTADOR DE VIDRIO UTILIZANDO UNA RED NEURONAL DE RETROPROPAGACION

Nicolás Flores Cardona, M.C.

Instituto Tecnológico y de Estudios Superiores de Monterrey, 1999

Asesor de la tesis: Rogelio Soto Rodríguez, Ph. D.

Resumen

En la presente tesis se estudia el comportamiento de la temperatura en un alimentador de vidrio utilizado en la manufactura de envases de vidrio. El estudio se realiza sobre un sólo alimentador de vidrio hacia una máquina formadora de envases tipo I.S. (Individual Section). Se realizan mediciones a variables claves del proceso y se genera un modelo del alimentador. El modelo del alimentador se obtiene en base a una red neuronal de retropropagación, se realizan simulaciones y se presentan las conclusiones obtenidas. Este modelo se utilizará para fines de optimización sobre un control PID existente.

Modelación de un alimentador de vidrio utilizando una red neuronal

Indice

Agradecimientos	vii
Resumen.....	ix
Indice.....	xi
Tabla de Figuras.....	xiii
1 Introducción	1
1.1 Antecedentes.....	1
1.2 Objetivo y Contribución de la Tesis.....	2
1.3 Contenido de la Tesis	3
2 Proceso de Formado de Envases de Vidrio	5
2.1 Descripción del Proceso	5
2.2 Composición y Propiedades del Vidrio	5
2.3 Fundición y Generación de Vidrio	6
2.4 Distribución de Vidrio	7
2.5 Formación de Envases de Vidrio.....	8
2.6 Control de Temperatura del Horno y de Alimentadores	9
3 Redes Neuronales Aplicadas a la Identificación de Procesos	11
3.1 Generalidades	11
3.2 Utilización de Redes Neuronales en Control de Procesos.....	14
3.3 Identificación No-Paramétrica Mediante una Red Neuronal.	14
3.4 Red de Retropropagación	15
4 Desarrollo de la Identificación	21
4.1 Planteamiento del desarrollo.	21
4.2 Alcance	24
4.3 Adquisición de Datos.....	25
4.4 Diseño de la Red Neuronal.....	27
4.5 Resultados Experimentales de la Identificación y Simulación del Proceso.	29
4.6 Diseño del Controlador Neuronal.....	33
4.7 Desarrollo de la Red Neuronal para el Control de la Planta.....	34
5 Conclusiones	37
5.1 Descripción del Experimento	37
5.2 Adquisición de Datos.....	38
5.3 Diseño de la Red Neuronal	38
5.4 Resultados Experimentales.....	39
5.5 Trabajos Futuros	39
Bibliografía	41
Apéndice	43
A. Tabla de entrada aplicada y de salida obtenida del sistema.	43
B. Tabla de entrada y de salida normalizadas.....	44
C. Programa de Matlab para identificación.	45
D. Pesos y valores de polarización de la Red de Identificación.....	46
E. Diagrama del Simulink para simulaciones.....	49
Vita.....	51

Modelación de un alimentador de vidrio utilizando una red neuronal

Tabla de Figuras

Fig. 1 - Viscosidad Log (Poison)	6
Fig. 2 – Distribución típica de una línea de producción de envases de vidrio.....	7
Fig. 3 - Refinador y Alimentadores de Vidrio	8
Fig. 4 - Gota de Vidrio, Preforma y Envase Formado	8
Fig. 5 - Esquema de una neurona.....	11
Fig. 6 - Esquema de una red neuronal.....	12
Fig. 7 – Representación gráfica de las funciones características	13
Fig. 8 - Identificación de la planta	15
Fig. 9 – Red de Retropropagación	16
Fig. 10 – Diagrama de bloques del alimentador	23
Fig. 11 – Diagrama de la zona a identificar (Canal 2).....	24
Fig. 12 – Respuesta experimental del proceso a los cambios en forma de escalón.....	26
Fig. 13 – Diagrama de la red neuronal utilizada	28
Fig. 14 – Respuesta de la Red Neuronal al ser entrenada con datos reales	30
Fig. 15 – Salida Deseada y Salida Real de la Red Neuronal	31
Fig. 16 – Respuesta de la red entrenada ante cambios escalón.....	32
Fig. 17 - Identificación de modelo inverso de la planta.....	33
Fig. 18 – Control en base a una red neuronal	34
Fig. 19 – Respuesta del Controlador.....	35

1 Introducción

1.1 Antecedentes

En la actualidad, existe gran competencia en el mercado del vidrio, al igual que en muchas ramas de la industria, por lo que es muy común que haya gran variedad de productos por fabricar. Unido a otros factores las corridas de producción de envases han disminuido sus períodos de fabricación; esto hace que en intervalos cortos se presenten frecuentemente corridas de producción con duración menor a un día, lo cual hace que existan varios cambios de productos en un sólo día. Estos cambios frecuentes obliga a realizar ajustes en las distintas variables de proceso en la línea de producción donde se están fabricando los productos. Esto hace que la variación en el proceso de producción de envases de vidrio sea muy grande y por el esquema de producción, repercute en el proceso de fabricación de otros productos que se estén produciendo en otras líneas adyacentes a la que se está realizando el cambio de producto. Debido a lo anterior, es necesario disminuir al mínimo el tiempo del proceso de ajuste en las variables durante los cambios de producción.

En el proceso de fabricación de envases de vidrio, existen varios alimentadores instalados en cada horno fundidor, y por lo tanto igual número de líneas de producción. Existe una problemática al realizar cambios de velocidad en las líneas de producción, ya que la extracción de vidrio del horno se ve modificada y afecta en los alimentadores vecinos, por lo que es necesario conocer a detalle el proceso de fundición y distribución de vidrio a las máquinas de producción. El proceso a estudiar es el que existe en los alimentadores de vidrio, por lo que en el presente trabajo se plantea una modelación de un alimentador, generándo así un campo de estudio para futuras tesis.

Se realiza una modelación del proceso de cambio de temperatura de una zona en un alimentador de vidrio utilizando una red neuronal de retropropagación. La técnica utilizada para la identificación del proceso es la no-paramétrica, en donde en base a datos de entrada y de salida se realiza un mapeo utilizando la red neuronal de retropropagación.

Esta red realiza una interpolación en la salida cuando se le proporciona entradas no conocidas; lo hace en base a lo aprendido durante su etapa de aprendizaje.

La técnica utilizada para la identificación del proceso no requiere de conocimiento a fondo del proceso, ya que realiza iteraciones para ajustar los parámetros de la red y verifica el error resultante de lo que genera la red al momento, contra lo que arroja el proceso, hasta que se llegue a un error aceptable.

No se tiene literatura de estudios anteriores para la generación de un modelo de alimentador utilizando una red neuronal. Se han hecho estudios para el control de procesos [6], diagnóstico de fallas [5] e identificaciones de otros tipos de procesos [13]. Una de las aplicaciones típicas de las redes neuronales es el reconocimiento de patrones, ya sea escritura u objetos [17].

1.2 Objetivo y Contribución de la Tesis

El objetivo de este trabajo de tesis es la generación de un modelo en una zona de un alimentador de vidrio utilizando técnicas de inteligencia artificial, específicamente mediante redes neuronales de retropropagación. Para la generación del modelo se realizará una identificación del proceso de calentamiento de una zona del alimentador, se utilizará el paquete computacional Matlab junto con el módulo Simulink, éstos para el desarrollo de programas para la identificación y la generación de simulaciones. Se planteará el desarrollo de un controlador neuronal para la zona identificada.

La contribución de la tesis es generar un modelo del alimentador utilizando una red neuronal de retropropagación y comprobar que las redes neuronales tienen aplicación en procesos industriales, siendo ésta, la modelación de procesos. También este modelo podrá ser tomado como punto inicial para modelaciones más complejas, al igual que para la sintonía y optimización de controladores de temperatura.

1.3 Contenido de la Tesis

Durante el desarrollo de la tesis se describirá el proceso de formado de envases de vidrio, la aplicación de redes neuronales en la identificación de procesos, el desarrollo de la identificación y las conclusiones obtenidas.

En el Capítulo 2 se describe el proceso de formado de envases de vidrio, mencionando en forma básica la composición y las temperaturas importantes en la fundición de vidrio y en el formado del envase. También se describen los procesos de distribución de vidrio a la máquina formadora y el de formado del envase.

En el Capítulo 3 se plantea la aplicación de las redes neuronales en la identificación de procesos, se exponen los conceptos involucrados en las redes neuronales y su utilización en el control de procesos. Se describe el procedimiento de aprendizaje de una red de retropropagación.

En el Capítulo 4 se realiza el desarrollo de la identificación, planteando el desarrollo del experimento y su alcance. Se diseña la red neuronal a utilizar y se presentan los resultados obtenidos de la identificación del proceso y de las simulaciones realizadas. Se diseña un controlador neuronal y se plantea su implementación.

En el Capítulo 5 se mencionan las conclusiones realizadas en base al modelo y los resultados obtenidos, se genera un resumen y se plantean alternativas para trabajos futuros.

2 Proceso de Formado de Envases de Vidrio

2.1 Descripción del Proceso

El proceso de producción de envases de vidrio se inicia desde la materia prima, la cual es una mezcla de óxidos y está basada en arena sílica. Esta mezcla es fundida en un horno, para generar el vidrio, el cual es llevado por medio de refinadores y alimentadores a varias máquinas formadoras de envases; denominadas I.S. (Individual Section). El vidrio llega a la máquina I.S. y ahí es formado el envase, para posteriormente ser llevado por bandas transportadoras al horno de recocido para liberarlo de esfuerzos generados durante la formación del envase.

2.2 Composición y Propiedades del Vidrio

El vidrio es compuesto de una mezcla de distintos óxidos, la composición química generalmente se constituye de los siguientes compuestos: SiO_2 , Al_2O_3 , Fe_2O_3 , CaO , MgO , Na_2O , K_2O , SO_3 , BaO , Cr_2O_3 , F_2 y TiO_2 . Esta composición tiene ciertas propiedades, entre las cuales existe un comportamiento asociado a la propiedad de la temperatura, este comportamiento tiene que ver con la viscosidad del vidrio.

Cuando el vidrio se encuentra en estado fundido existen temperaturas claves que repercuten directamente en su viscosidad. El término viscosidad es definido como "el grado al cual un fluido se resiste a fluir bajo una fuerza aplicada" [4]. Una unidad de medición de la viscosidad es el poison, el cual es la cantidad de fuerza aplicada a un área fija, que causa que el vidrio se mueva. Por lo tanto, a mayor viscosidad, mayor fuerza se requerirá para producir movimiento y entonces el vidrio fluye en menor proporción. Aplicando este término a una composición de vidrio, hablaremos de "Viscosidad Log", o el logaritmo de la viscosidad en poison.

Existen tres viscosidades claves en la producción de artículos de vidrio, las cuales son viscosidad Log 2, viscosidad Log 3 y viscosidad Log 7. La viscosidad Log 2, o 10^2 (100)

poison, es la viscosidad del vidrio a la temperatura de fundición, esta temperatura generalmente es de 1463°C (2666°F) y depende de la composición del vidrio. La temperatura de Log 2 es la temperatura característica en el horno fundidor.

La siguiente viscosidad importante es la Log 3, o 10^3 (1000) poison, en donde la temperatura a esta viscosidad es la teórica que debe tener la gota de vidrio justamente antes de entrar a la máquina formadora y por lo tanto el refinador y alimentador deben estar trabajando a mayor temperatura que la de Log 3. La temperatura de Log 3 debe estar alrededor de los 1200°C (2192°F).

Por último, la viscosidad Log 7, o 10^7 poison, es a la temperatura en la que el vidrio puede mantenerse en la forma en que fue moldeado, esta temperatura está alrededor de los 773°C (1423°F). Este punto es donde el artículo sale de la máquina formadora.

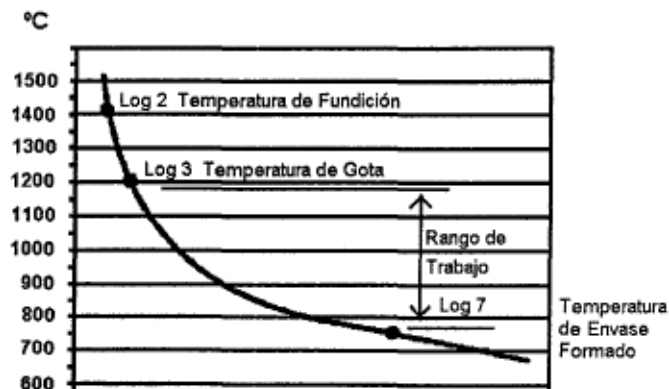


Fig. 1 - Viscosidad Log (Poison)

2.3 Fundición y Generación de Vidrio

La generación de vidrio se realiza en un horno donde se funde una mezcla de óxidos y arenas, principalmente sílica. La fundición se realiza alrededor de la temperatura de Log 2 (1463 °C), esta temperatura base puede variar dependiendo del color y las materias primas utilizadas. Debe de existir una homogeneidad en la distribución de temperatura en el horno, esto es con el fin de que la materia sea fundida correctamente y así generar vidrio de alta calidad.




Fig. 2 – Distribución típica de una línea de producción de envases de vidrio

2.4 Distribución de Vidrio

Una vez generado el vidrio, éste debe ser distribuido a las distintas líneas de producción existentes en el horno. El vidrio es llevado a las máquinas formadoras a través de un refinador y de varios alimentadores. El refinador y los alimentadores están hechos de componentes refractarios y son divididos en distintas zonas para el enfriamiento y acondicionamiento del vidrio.

Dependiendo de la capacidad del horno fundidor y de la cantidad de máquinas a alimentar es configurado el arreglo refinador-alimentadores en distintas zonas, las cuales son llamadas: alcoba, canal 1, canal 2, y noria. Para acondicionar el vidrio a las necesidades del producto en fabricación, existen distintos lazos de control de temperatura en cada una de las zonas del alimentador.

En la parte final del alimentador, existe lo que se le llama noria, que es la zona donde el vidrio es entregado a la máquina formadora. En la noria existe uno o varios orificios para dosificar las gotas de vidrio a la máquina formadora para formar los envases.




Fig. 3 - Refinador y Alimentadores de Vidrio

2.5 Formación de Envases de Vidrio

El envase es fabricado en la máquina formadora de envases llamada I.S. A esta máquina le llega el vidrio en forma de gota y entra a un componente denominado bombillo. Aquí se obtiene lo que se llama preforma y la corona del envase. Mediante mecanismos de soplado o de prensado, la preforma es formada en el bombillo y posteriormente será pasada al molde donde el envase será formado. Mediante un mecanismo de inversión la preforma se transfiere al molde en donde, por mecanismos de soplado, el envase es finalmente formado.




Fig. 4 - Gota de Vidrio, Preforma y Envase Formado

2.6 Control de Temperatura del Horno y de Alimentadores

Se utilizan controladores de temperatura en el horno fundidor y en los alimentadores de vidrio. Los controladores dependen de la sintonía con la que son programados. Cada vez que varía el estiraje¹ en los alimentadores, y por supuesto en el horno, cambian las condiciones de operación y puede que sea necesario volver a sintonizar los lazos de control usados. Por esta situación se está proponiendo realizar un modelo del alimentador utilizando redes neuronales como punto inicial para encaminarnos hacia una modelación posterior de todo el conjunto de alimentadores, refinador y horno de fundición. Posteriormente el modelo será utilizado en el mejoramiento de los controladores existentes; los cuales generalmente son del tipo PID.

¹ Flujo volumétrico de vidrio que le es solicitado al alimentador.

3 Redes Neuronales Aplicadas a la Identificación de Procesos

3.1 Generalidades

Este esquema propone simular el comportamiento natural de las neuronas humanas. El sistema nervioso del ser humano está compuesto por millones de neuronas, que son células independientes que están conectadas entre sí, las cuales reaccionan al sentir cualquier impulso, éste es transportado mediante todas las neuronas interconectadas hasta el cerebro. Ahí es donde se procesa la acción a tomar al impulso recibido.

En un esquema artificial, la red neuronal trata de emular las acciones de las neuronas naturales, respondiendo a entradas que le son proporcionadas y son transportadas mediante la red neuronal para generar la respuesta a la entrada proporcionada.

Para que una red neuronal pueda responder en forma adecuada a cualquier entrada que se le proporcione, es necesario realizar una etapa de aprendizaje. Cada neurona, individualmente, tiene una función programada para generar la respuesta a la entrada proporcionada y a su vez su salida va a llegar ser la entrada a la siguiente o siguientes neuronas dentro de la red. Un esquema de una neurona se presenta en la Fig. 5.




Fig. 5 - Esquema de una neurona

Donde :

$$net_i = \sum_{j=1}^n x_j \omega_j$$

la cual es la entrada neta a la neurona i ,

$$y_i = f_i(net_i)$$

es la salida, la cual se obtiene con una función característica de la neurona i ,

$$x_{1..n}$$

son las entradas a la neurona i , ya sea las entradas iniciales a la red o las salidas de las neuronas anteriores,

$$\omega_{1..n}$$

son los pesos o constantes de incremento o decremento por la que las entradas $x_{1..n}$ son multiplicadas,

La red neuronal consiste en la unión de varias neuronas con interconexiones entre ellas. Generalmente la red neuronal se componen de una capa de entrada, una o mas capas intermedias y una capa de salida.

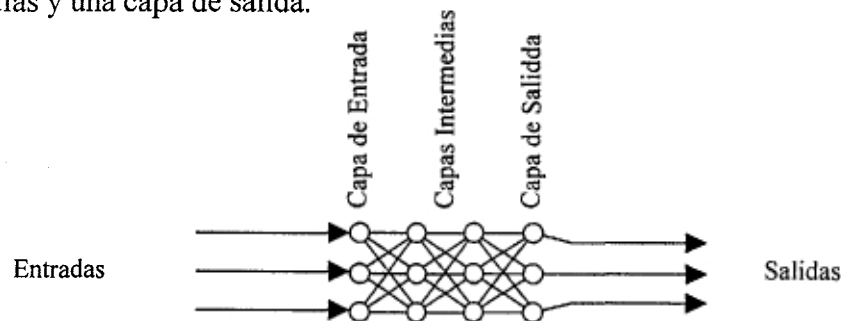


Fig. 6 - Esquema de una red neuronal

Las entradas son proporcionadas a la red por la capa de entrada, las operaciones matemáticas son realizadas en las capas intermedias, para al final proporcionar los resultados por la capa de salida. Las operaciones matemáticas son los resultados de cada una de las neuronas, por lo que cada una genera una salida y_i , las cuales se van distribuyendo entre todas las neuronas, llegando hasta la salida.

Las funciones características de las neuronas $f(net_i)$ más usadas son: lineal, sigmoideal y tangente hiperbólica, expresadas matemáticamente como:

(a) $y_i = net_i$

$$(b) \quad y_i = \frac{1}{1 + e^{net_i}}$$

$$(c) \quad y_i = \frac{(e^{net_i})^2 - 1}{(e^{net_i})^2 + 1}$$




Fig. 7 – Representación gráfica de las funciones características

En base a las operaciones que realiza la red neuronal, podemos decir que la red neuronal realiza un mapeo de las entradas contra las salidas y para una entrada no conocida, realizará una interpolación en base al aprendizaje obtenido para dar una salida; para demostración de convergencia ver [18]. La calidad de su respuesta depende en gran medida a su entrenamiento, por lo que al no ser entrenada adecuadamente podrá arrojar resultados incongruentes.

No existen reglas precisas para el entrenamiento de una red. Una muestra de patrones representativa del comportamiento a emular es suficiente, pero en ocasiones habrá que tomar una muestra mayor, esta decisión se realizará en base a los resultados obtenidos en pruebas con la red. La arquitectura de la red tampoco se determina en base a una regla, solamente las neuronas de entrada y de salida son las que se pueden determinar, ya que son las entradas y salidas del comportamiento a emular. El número de capas intermedias y su tamaño se determinan más bien en base a la experiencia, ya que se seleccionan en

base a los resultados obtenidos. Generalmente es suficiente una capa intermedia, pero el número de neuronas en esta capa depende del rendimiento que se esté buscando de la red.

3.2 Utilización de Redes Neuronales en Control de Procesos.

Existen cuatro usos principales para las redes neuronales dentro de control de procesos; unos usos están enfocados a la modelación de procesos y otros a control en sí; éstos son:

- Identificación No-Paramétrica: desarrollo de cajas negras para la modelación del comportamiento entre entrada-salida del proceso.
- Identificación Paramétrica: identificación de características estructurales y de parámetros para modelos físicos.
- Modelación Inversa: desarrollo de modelos que predicen las entradas al proceso correspondiente a las salidas de éste.
- Autosintonía del Control : estimación de valores apropiados para los parámetros del control, principalmente las ganancias del PID.

La identificación a realizar en el presente trabajo será por medio de identificación no-paramétrica, en la cual se utilizan los datos del proceso (entrada-salida) para el entrenamiento de la red. En el proceso de entrenamiento de la red, se irán ajustando los pesos de la red hasta que el modelo de salida de la red pronostique las salidas del proceso.

3.3 Identificación No-Paramétrica Mediante una Red Neuronal.

La identificación realizada mediante una red neuronal es básicamente colocar en paralelo a la planta a identificar, la red que va a tomar el comportamiento de la planta. Esta red tendrá que pasar por una etapa de aprendizaje del comportamiento de la planta.

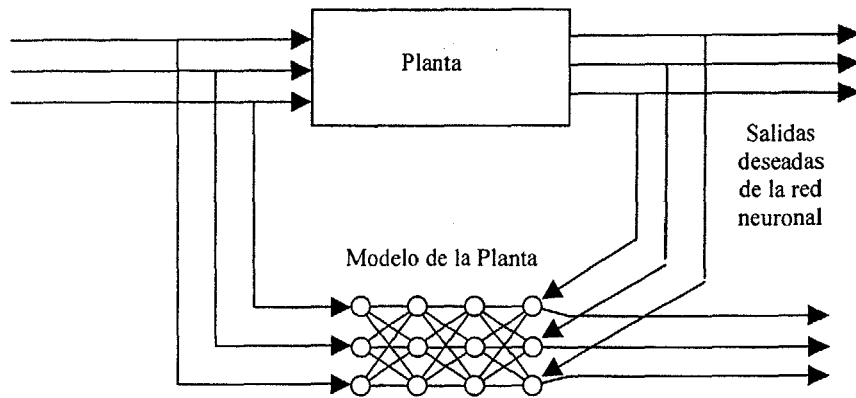


Fig. 8 - Identificación de la planta

En este esquema se realizará un mapeo de las entradas a la planta contra las salidas de la planta, o aproximación de la función característica de la planta [18]. Los datos de la entrada a la planta y los de salida se le proporcionarán a la red neuronal para entrenarla y que obtenga el modelo que corresponde a la planta.

Los datos que entrarán a la red serán las variables de operación que entran a la planta y lo que entrega la planta deberán ser las salidas. En el proceso de aprendizaje, las salidas de la planta son sobrepuestas a las salidas de la red para que se calcule un error de lo que la red genera como salida, contra lo que debe salir de la red y así se realizarán operaciones de distribución del error para ir ajustando los pesos de la red en cada ciclo de aprendizaje hasta que se obtenga un valor de error mínimo aceptable. La red resultante a este proceso se le conoce como Red de Retropropagación (Backpropagation Network).

3.4 Red de Retropropagación

Esta red consta de unidades de entrada, conjuntando la capa de entrada, unidades ocultas que forman la capa oculta y las unidades de salida, formando la capa de salida.

Para diseñar correctamente la red es necesario establecer el número de neuronas (unidades) en cada una de las capas y definir los pesos que va a tener cada una de las neuronas. Para establecer los pesos durante el entrenamiento, se requiere de un algoritmo para el aprendizaje de la red, llamado Regla Delta Generalizada, ésta toma los datos de entrada y salida, y mediante iteraciones va ajustando los pesos para minimizar el error existente a la salida.




Fig. 9 – Red de Retropropagación

Para iniciar el entrenamiento, primeramente hay que seleccionar un patrón de datos de entrada a la red a entrenar. El patrón de datos puede ser una muestra representativa del comportamiento a aprender. Ya una vez teniendo el patrón muestra se pasa a aplicar el algoritmo de la Regla Delta Generalizada, el cuál es presentado a continuación [2].

1. Aplicar el vector de entrada $\mathbf{x}_p = (x_{p1}, x_{p2}, \dots, x_{pN})^t$ a las unidades de entrada.
El término “p” refiere al número de patrón de entrada.
2. Calcular los valores de entrada-net a las unidades de las capas ocultas.

$$net_{pj}^h = \sum_{i=1}^N \omega_{ji}^h x_{pi} + \theta_j^h$$

Donde ω_{ji}^h es el peso de la conexión desde la unidad de entrada i , y θ_j^h es la

constante de polarización. El término “h” refiere al número de neurona de la capa oculta, la cual se enumerará de 1 a L.

3. Calcular las salidas de la capa oculta.

$$i_{pj} = f_j^h(\text{net}_{pj}^h)$$

4. En la capa de salida, calcular los valores de entrada-net a cada unidad.

$$\text{net}_{pk}^o = \sum_{j=1}^L \omega_{kj}^o i_{pj} + \theta_k^o$$

El término “o” refiere al número de neurona de la capa de salida, la cual se enumerará de 1 hasta M.

5. Calcular las salidas.

$$o_{pk} = f_k^o(\text{net}_{pk}^o)$$

6. Calcular el error para las unidades de salida.

$$\delta_{pk}^o = (y_{pk} - o_{pk}) f_k^{\prime o}(\text{net}_{pk}^o)$$

Donde y_{pk} es la salida deseada para el patrón p . $f_k^{\prime o}$ es la derivada de f_k^o , que para el caso de la función sigmoideal

$$f_k^{\prime o}(\text{net}_{pk}^o) = (1 + e^{-\text{net}_{pk}^o})^{-1}$$

La derivada es

$$f_k^{\prime o} = f_k^o(1 - f_k^o) = o_{pk}(1 - o_{pk})$$

7. Calcular el error para las unidades ocultas.

$$\delta_{pj}^h = f_j^{\prime h}(\text{net}_{pj}^h) \sum_k \delta_{pk}^o \omega_{kj}^o$$

8. Actualizar pesos en la capa de salida.

$$\omega_{kj}^o(t+1) = \omega_{kj}^o(t) + \eta \delta_{pk}^o i_{pj}$$

Donde η es el coeficiente de aprendizaje, este factor será clave para la velocidad de convergencia de la red. Este debe de estar en el orden de 0.05 a 0.25. Influirá en gran medida a la convergencia del error.

Otra forma de modificar la velocidad de convergencia del error, es la técnica llamada momentum. Esta técnica actualiza los pesos mediante un porcentaje del cambio anterior del peso, tendiendo a mantener el cambio de los pesos en la misma dirección.

$$\omega_{kj}^s(t+1) = \omega_{kj}^s(t) + \eta \delta_{pk}^s i_{pj} + \alpha \Delta_p \omega_{kj}^s(t-1)$$

Donde Δ_p es el cambio del peso y α es el parámetro momentum; el cuál se debe fijar en un valor positivo menor que 1.

9. Actualizar pesos en la capa oculta.

$$\omega_{ji}^h(t+1) = \omega_{ji}^h(t) + \eta \delta_{pj}^n x_i$$

Al igual que en la capa de salida, se puede usar la técnica de momentum.

10. Calcular el error de aprendizaje.

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$$

11. Regresar al punto número 1 para aplicar el siguiente patrón y volver a realizar cálculos.
12. Cuando el error de aprendizaje sea menor a un mínimo seleccionado se termina el diseño de la red neuronal.

Los parámetros característicos de la red de retropropagación son los pesos ω , el número de capas y el número de unidades o neuronas en cada una de las capas que la conforman.

Una vez obtenidos los pesos ω , éstos se integran en la red integrando la red final. Al tener la red se introduce la entrada y la red transmitirá los resultados de cada una de sus neuronas por todas sus capas hasta obtener el resultado final en la capa de salida. La rapidez de la red dependerá del tamaño y arquitectura de ella.

Este algoritmo de retropropagación ya se encuentra implementado en paquetes computacionales que utilizan redes neuronales. Para el caso de la presente tesis se utilizará el módulo de redes neuronales versión 2.0.4 del paquete Matlab versión 5.1.0.421, el cual ya tiene implementado este algoritmo.

4 Desarrollo de la Identificación

4.1 Planteamiento del desarrollo.

La planta a identificar su modelo será un alimentador de 5 zonas; las cuales son:

- Refinador
- Alcoba
- Canal 1
- Canal 2
- Noria

Las variables de entrada y salida para cada zona son las siguientes:

Refinador

Entradas

- Presión de Gas en Válvula de Enfriamiento
- Presión de Gas en Válvula de Calentamiento
- Temperatura de piso de garganta
- Nivel de Vidrio
- Estiraje

Salidas

- Temperatura Superior del vidrio
- Temperatura Medio del vidrio
- Temperatura Fondo del vidrio

Alcoba

Entradas

- Temperatura Superior del vidrio de salida de refinador
- Temperatura Medio del vidrio de salida de refinador
- Temperatura Fondo del vidrio de salida de refinador
- Presión de Gas en Válvula de Calentamiento
- Nivel de Vidrio
- Estiraje

Salidas

- Temperatura Superior del vidrio
- Temperatura Medio del vidrio
- Temperatura Fondo del vidrio

Canal 1

Entradas

- Temperatura Superior del vidrio de salida de alcoba
- Temperatura Medio del vidrio de salida de alcoba
- Temperatura Fondo del vidrio de salida de alcoba
- Presión de Gas en Válvula de Calentamiento
- Presión de Gas en Válvula de Enfriamiento
- Nivel de Vidrio
- Estiraje

Salidas

- Temperatura Superior Izq. del vidrio
- Temperatura Medio Izq. del vidrio
- Temperatura Fondo Izq. del vidrio
- Temperatura Superior Cen. del vidrio
- Temperatura Medio Cen. del vidrio
- Temperatura Fondo Cen. del vidrio
- Temperatura Superior Der. del vidrio
- Temperatura Medio Der. del vidrio
- Temperatura Fondo Der. del vidrio

Canal 2

Entradas

- Temp. Superior Izq. del vidrio de salida de canal 1
- Temp. Medio Izq. del vidrio de salida de canal 1
- Temp. Fondo Izq. del vidrio de salida de canal 1
- Temp. Superior Cen. del vidrio de salida de canal 1
- Temp. Medio Cen. del vidrio de salida de canal 1
- Temp. Fondo Cen. del vidrio de salida de canal 1
- Temp. Superior Der. del vidrio de salida de canal 1
- Temp. Medio Der. del vidrio de salida de canal 1
- Temp. Fondo Der. del vidrio de salida de canal 1
- Presión de Gas en Válvula de Calentamiento
- Presión de Gas en Válvula de Enfriamiento
- Nivel de Vidrio
- Estiraje

Salidas

- Temperatura Superior Izq. del vidrio
- Temperatura Medio Izq. del vidrio
- Temperatura Fondo Izq. del vidrio
- Temperatura Superior Cen. del vidrio
- Temperatura Medio Cen. del vidrio
- Temperatura Fondo Cen. del vidrio
- Temperatura Superior Der. del vidrio
- Temperatura Medio Der. del vidrio
- Temperatura Fondo Der. del vidrio

Noria

Entradas

- Temp. Superior Izq. del vidrio de salida de canal 2
- Temp. Medio Izq. del vidrio de salida de canal 2
- Temp. Fondo Izq. del vidrio de salida de canal 2
- Temp. Superior Cen. del vidrio de salida de canal 2
- Temp. Medio Cen. del vidrio de salida de canal 2
- Temp. Fondo Cen. del vidrio de salida de canal 2
- Temp. Superior Der. del vidrio de salida de canal 2
- Temp. Medio Der. del vidrio de salida de canal 2
- Temp. Fondo Der. del vidrio de salida de canal 2
- Presión de Gas en Válvula de Calentamiento
- Nivel de Vidrio
- Estiraje

Salidas

- Temperatura Superior Izq. del vidrio
- Temperatura Medio Izq. del vidrio
- Temperatura Fondo Izq. del vidrio
- Temperatura Superior Cen. del vidrio
- Temperatura Medio Cen. del vidrio
- Temperatura Fondo Cen. del vidrio
- Temperatura Superior Der. del vidrio
- Temperatura Medio Der. del vidrio
- Temperatura Fondo Der. del vidrio

Todas estas 5 zonas se encuentran en forma secuencial, por lo que las salidas de una son las entradas de otras, por lo tanto, iniciando con el refinador, las salidas del refinador son las entradas a la alcoba, las salidas de la alcoba son las entradas al canal 1, las salidas del canal 1 son las entradas al canal 2 y las salidas del canal 2 son las entradas a la noria.

Esquematizando esto en un diagrama, tenemos lo siguiente:

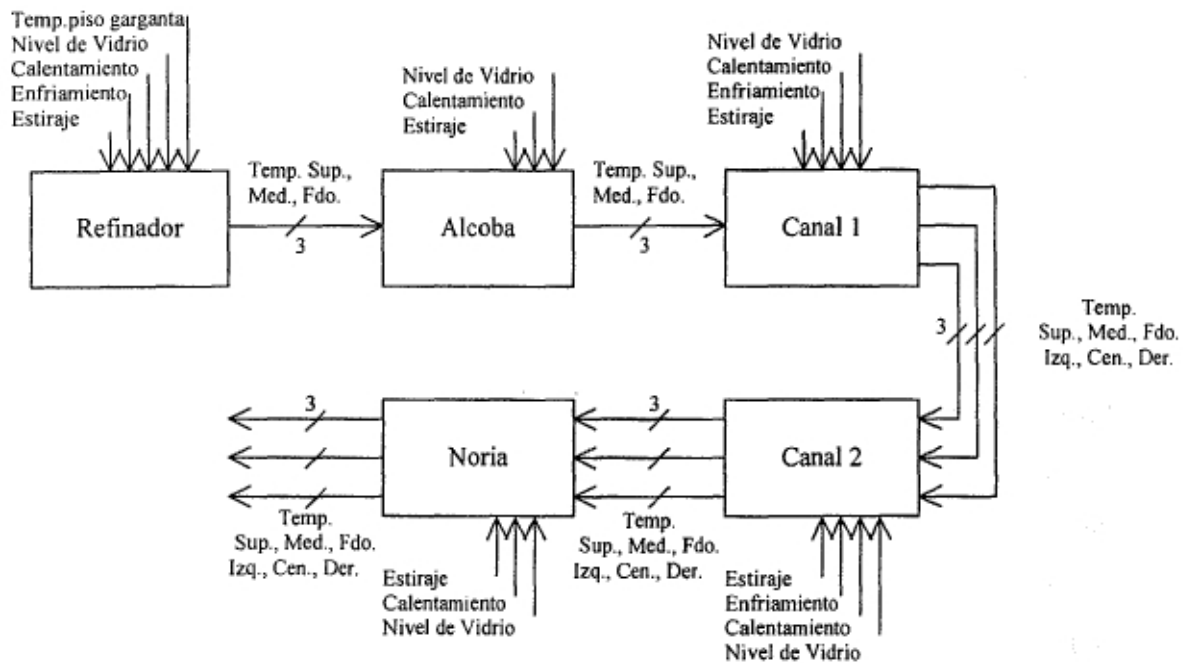


Fig. 10 – Diagrama de bloques del alimentador

La instrumentación a utilizar para obtener los valores de estas variables de proceso son:

Variable

- Presión de la Mezcla Aire-Gas
- Temperatura Superior, Media, Inferior

Instrumento

- Transmisores de Presión
- Termopar Triple

Una vez teniendo los valores de comportamiento de las variables, éstos se llevarán fuera de línea y con ayuda de una computadora y un paquete computacional, se diseñará la red y se generará el proceso de aprendizaje para obtener finalmente el modelo del alimentador. Se tendrá que realizar identificaciones independientes en cada una de las zonas y por lo tanto se obtendrá un juego de redes neuronales correspondiendo cada red a cada zona identificada. El modelo final se obtendrá al unir todas las redes generando así un conjunto de redes neuronales que nos darán el modelo del alimentador completo.

4.2 Alcance

Para simplificar el desarrollo del experimento se va a realizar la identificación del modelo a una sola zona del alimentador. La zona seleccionada es el canal 2; se seleccionó esta zona por tener una mejor instrumentación instalada y porque la zona anterior, la cual es el canal 1, puede controlarse fácilmente, debido también a que se cuenta con una buena instrumentación en esta zona.

La identificación para las demás zonas se puede realizar en forma similar, ya que el comportamiento y las variables involucradas son similares entre todas las zonas del alimentador.

El proceso a identificar queda de la siguiente manera:

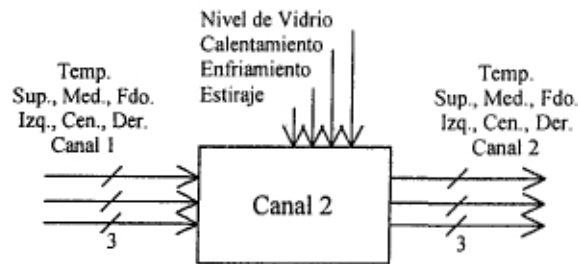


Fig. 11 – Diagrama de la zona a identificar (Canal 2)

Se van a descartar las variables del nivel de vidrio, enfriamiento, estiraje y las temperaturas de entrada, ya que estas variables son constantes en el punto a analizar, además sólo se tomará la temperatura superior centro, ya que el control instalado sólo realiza acciones sobre temperaturas superiores y se tomará el del centro por simplificación del modelo. En el caso de realizar el modelo completo del alimentador sí se requerirá tomar en cuenta todas las variables.

4.3 Adquisición de Datos.

La adquisición de datos se realizó en el sistema de control que se tiene instalado en el alimentador. Se aprovechó este sistema utilizando su instrumentación y recopilación de datos históricos.

Inicialmente se trabajó con datos recopilados cada minuto y con el control funcionando en automático. Para realizar movimientos y pruebas a respuestas a escalones se tuvo que poner el control fuera de línea y manualmente realizar los cambios de referencia para probar las respuestas a escalones hacia arriba y hacia abajo. Se observó el comportamiento de la zona del canal 2 tomando en cuenta sólo la temperatura de entrada superior a esta zona, la presión de gas que se estaba proporcionando por el control para realizar calentamiento y la temperatura de salida superior de esta zona.

Los cambios de referencia se realizaron de la siguiente forma: se ajustó la temperatura de entrada a que fuera constante, haciendo que la temperatura del canal 1 fuera de 1157 °C, al igual, se colocó la abertura del quemador para calentamiento en un 54 % de la abertura máxima hasta que se estabilizó la temperatura de salida del canal 2, la cual fue de 1147 °C. Después de esto se incrementó la abertura del quemador en 15 puntos porcentuales llegando a 69 % y se esperó la estabilización de la temperatura de salida, la cual llegó a 1180 °C. Posteriormente se decrementó la abertura del quemador en 5 puntos, llegando a 64 %, y se esperó la estabilización de la temperatura de salida, la cual llegó a 1173 °C. Con esto se dió por terminada la prueba para la adquisición de datos.

Las variables que fueron tomadas para la identificación son: el porcentaje de abertura del quemador como dato de entrada al sistema y como salida fue la temperatura que se lee en la parte superior del termopar en la zona del canal 2. Además de haber ajustado la temperatura de entrada a 1157 °C, también el estiraje y el enfriamiento de la zona fueron constantes. El estiraje fue de 81.2 toneladas por día, resultado de tener trabajando la máquina formadora a una velocidad de 60 cortes por minuto, con 2 cavidades en sus

moldes y un peso por envase de 470 gramos. El enfriamiento en la zona se ajustó en un 26 % de su enfriamiento máximo.

El procedimiento seguido durante la adquisición de datos fue el siguiente:

- Se deshabilitó la operación automática del controlador y el calentamiento de la zona quedó funcionando en forma manual.
- Se verificó que el proceso estuviera estable en una cierta temperatura.
- Se empezó a grabar información.
- Se incrementó el porcentaje de abertura del quemador en 15 puntos porcentuales.
- Se esperó a que el proceso se estabilizara.
- Se decrementó el porcentaje de abertura del quemador en 5 puntos porcentuales.
- Se esperó a que el proceso se estabilizara.
- Se terminó de grabar información.
- Se volvió a operar en modo automático el controlador de temperatura de la zona.

Al haber hecho lo anterior se obtuvieron los datos de entrada y salida a cambios en forma de escalón. Con la adquisición de datos se puede empezar a trabajar con la identificación del proceso mediante la red neuronal, primeramente diseñando la red. La gráfica con los datos de entrada y salida del proceso se presenta en la Fig. 12.




Fig. 12 – Respuesta experimental del proceso a los cambios en forma de escalón

La entrada es representada con la línea punteada, en tanto la salida se representa en línea continua. En el eje vertical se tiene un rango entre 0 y 1, lo que representa para la temperatura la variación de 33 °C; el 0 representa los 1147 °C iniciales y el 1 es la temperatura final de 1180 °C. En términos del actuador para calentamiento, el 0 representa el 54 % de abertura y el 1 representa el 69 %. El eje horizontal representa el tiempo y cada intervalo representa 1 minuto, resultando en una gráfica de 160 minutos.

La duración de la adquisición tardó aproximadamente 155 minutos, debido principalmente a lo lento del proceso. En la respuesta de la planta se puede notar que tiene un comportamiento críticamente amortiguado, por lo que pudiera considerarse como sistema de primer orden.

Se obtuvo una tabla con columna de entrada: el valor de la presión de gas para calentar; y la columna de salida: temperatura superior del termopar de salida del canal 2 (Apéndice A).

4.4 Diseño de la Red Neuronal.

Dentro del diseño de la red neuronal se tiene que tomar en cuenta el número de variables que se tienen en la entrada al igual que el número de salidas. En la entrada se tiene sólo una variable, la cual es la presión de gas para calentar, y en la salida sólo se tiene la temperatura de salida del canal 2.

La respuesta del sistema a identificar depende de los estados anteriores de entrada y de salida, ya que el proceso de cambio de temperatura de un objeto toma en cuenta el calentamiento que se la aplica y la temperatura a la cual se encuentra, debido a esto es conveniente proporcionar a la red las entradas y salidas anteriores [5]. Para lo cual después de realizar varias pruebas se decidió tomar en cuenta los 5 estados anteriores de las variables, por lo que es necesario tener a la entrada de la red 11 neuronas.

La cantidad de neuronas en la entrada resulta de tener una entrada y que para esa entrada será necesario tener sus 5 estados anteriores, para lo cual nos suma un total de 6 neuronas. También hay que tomar en cuenta a la entrada los estados de las salidas anteriores, por lo que hay que retroalimentar las 5 salidas anteriores; por lo que nos resulta en un total de 11 neuronas de entrada (ver Apéndice E).

Para la capa intermedia se seleccionó un total de 100 neuronas, esto con el fin de obtener una cantidad de nodos en donde se puedan realizar operaciones y obtener el modelo deseado. La cantidad de neuronas en esta capa se seleccionó inicialmente a 100, se realizaron pruebas y se obtuvieron resultados aceptables, por lo que ya no se probó con otra cantidad de neuronas en la capa intermedia.

En la capa de salida sólo se tiene 1 neurona, ya que sólo existe una salida; la cual es la temperatura de salida de la zona. Representando la red neuronal diseñada se tiene la siguiente configuración.




Fig. 13 – Diagrama de la red neuronal utilizada

Para la implementación de la red neuronal se utilizó el paquete computacional Matlab. Se configuró una red neuronal con 11 neuronas en la capa de entrada, 100 neuronas en la capa intermedia y 1 neurona en la capa de salida. Se diseñó con funciones de tangente hiperbólica en la capa de entrada y funciones lineales en la capa de salida.

4.5 Resultados Experimentales de la Identificación y Simulación del Proceso.

Una vez seleccionadas las variables y datos a interactuar con la red neuronal y diseñada ésta, se procede a la identificación de la planta. Mediante archivos de datos adquiridos de la zona del canal 2 a respuestas escalón se realizó un programa en Matlab (Apéndice C) proporcionando los datos de entrada y salida en base a matrices para entrenar a la red diseñada con el fin de identificar el modelo del canal 2. Los datos de entrada y salida fueron retrasados 5 veces dando un total de 11 entradas.

Durante la adquisición de datos, se incrementó la temperatura del canal 2 de 1147 °C a 1180 °C. Este incremento fue del orden de 33 °C. Debido a las funciones características de la red neuronal, estas temperaturas tuvieron que ser normalizadas en el rango de 0 a 1, al igual que la variable actuadora de entrada. La forma de realizar la normalización es la siguiente: tomar en cuenta los valores mínimos y máximos y restar a cada uno de los datos el valor mínimo, posteriormente dividir el resultado entre la diferencia entre el máximo y el mínimo, con lo anterior se obtendrán los valores entre 0 y 1, representando el comportamiento real del sistema (Apéndice B).

La información obtenida en la adquisición de datos y después de realizar la normalización se le es proporcionada al programa desarrollado en Matlab para la identificación. El programa desarrollado utiliza una red de retropropagación considerando la estructura de red diseñada en la sección de Diseño de la Red Neuronal.

En el programa de Matlab se diseñó la red neuronal utilizando la tangente hiperbólica como función característica en las neuronas de la capa intermedia, y la función lineal en la capa de salida. El error meta de finalización para el entrenamiento de la red para la identificación fue de 0.01. Y el parámetro momentum utilizado fue de 0.95. Se utilizó tangente hiperbólica, ya que permite mayor amplitud en los resultados de las operaciones, debido a que el rango de la función va de -1 a 1 .

Después de alcanzar el error meta, el programa genera los parámetros característicos de la red neuronal, en este caso como son 2 capas características se generan 2 juegos de pesos (ω) y de polarización (bias); ω_1, b_1 y ω_2, b_2 (Apéndice D). El comando del módulo de redes neuronales de Matlab utilizado fue trainbpx; el cuál genera los parámetros de la red en la forma de retropropagación rápida. Después de realizar el entrenamiento de la red neuronal se obtiene la respuesta de la red al proporcionarle la señal de entrada.

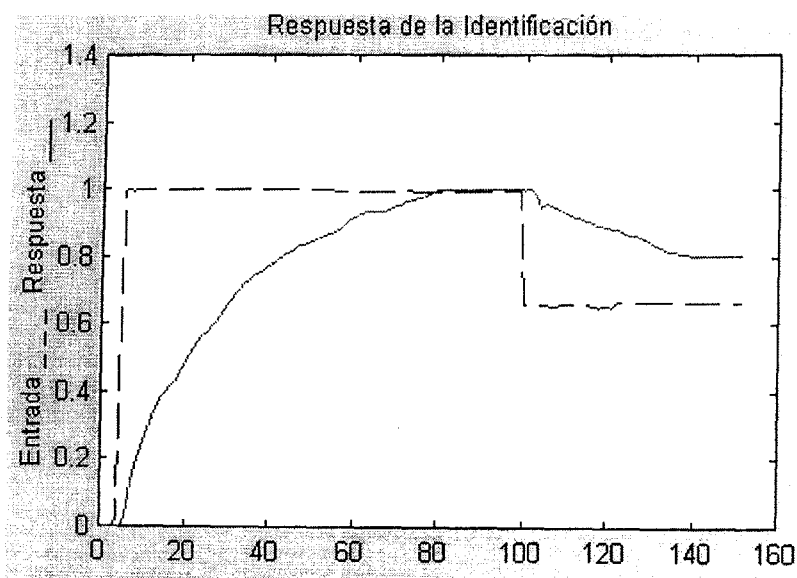


Fig. 14 – Respuesta de la Red Neuronal al ser entrenada con datos reales

La respuesta de la red al proporcionarle la entrada, se representa en la Fig. 14 como línea continua; la entrada se presenta en línea punteada. A este punto se logra ver que la respuesta de la red al proporcionarle la entrada genera una respuesta, simulada por la red, muy similar a la respuesta real. En la Fig. 15 se puede comparar la salida real del sistema con la salida simulada de la red. La salida del sistema se presenta con línea punteada y la salida de la red neuronal, con línea continua. Se observa en la figura que el resultado de la red es muy similar a la del proceso real.

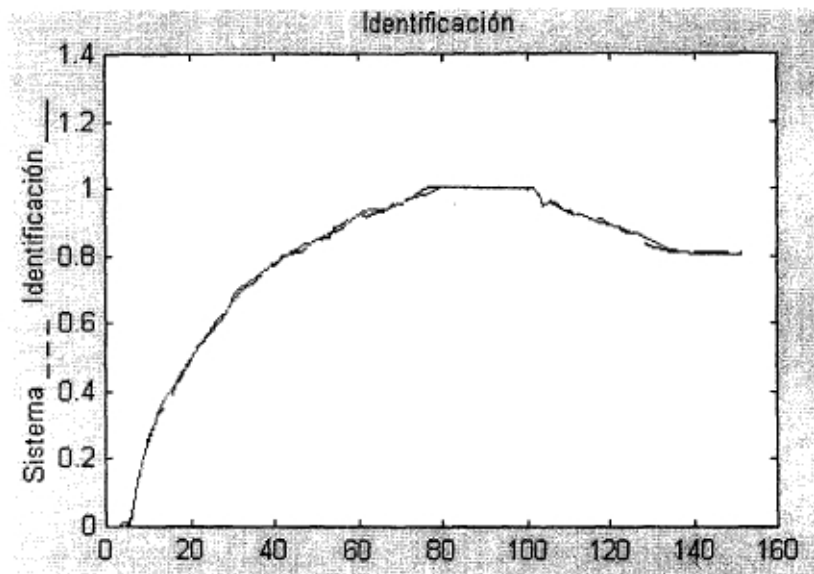


Fig. 15 – Salida Deseada y Salida Real de la Red Neuronal

Una vez realizada la identificación se requiere verificar si este modelo funciona aceptablemente, para lo cual hay que realizar simulaciones utilizando otro tipo de entrada. Para generar la simulación se desarrolló un módulo en Simulink dentro de Matlab utilizando los resultados obtenidos del programa para la identificación; los parámetros de la red ($\omega_1, b_1, \omega_2, b_2$). El módulo de simulación toma en cuenta la entrada a la planta junto con sus 5 estados anteriores para cada entrada, al igual considera las 5 salidas anteriores; éstas variables le son proporcionadas como entradas a sus 11 neuronas de entrada. El esquema del módulo de simulación de Simulink es presentado en el Apéndice E. La respuesta de la simulación con otra entrada distinta a la entrada con la que fue entrenada la red, se muestra en la Fig. 16.

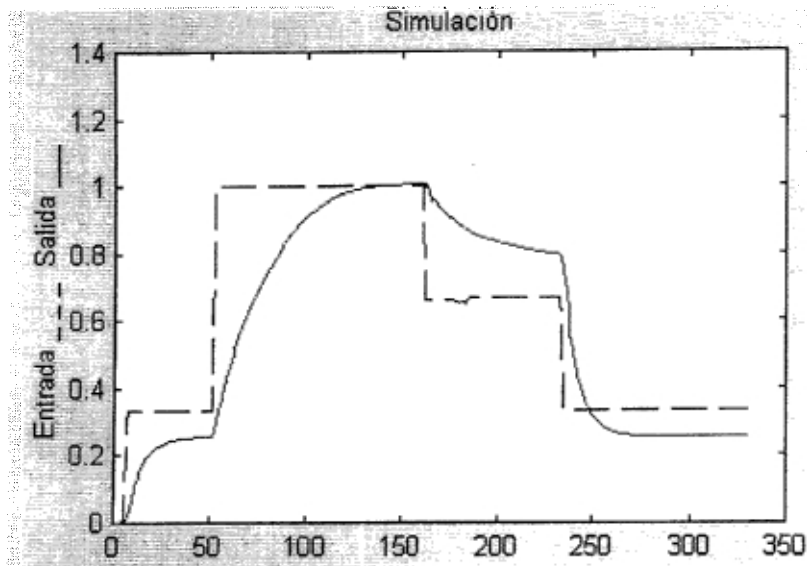


Fig. 16 – Respuesta de la red entrenada ante cambios escalón

Se puede notar que el comportamiento de la simulación es muy similar a al comportamiento real del proceso de cambio de temperatura en la zona del canal 2 del alimentador. En la Fig. 12 se presenta la respuesta experimental del proceso, en donde a la zona del canal 2 se le aplican dos cambios escalón y su respuesta tiende a alcanzar, en forma exponencial, a la entrada que se le está proporcionando. Cuando la red entrenada es expuesta a cambios escalón, también tiende a seguir a la entrada en forma exponencial (Fig. 16); comportamiento similar a la respuesta exponencial del proceso, concluyendo que el modelo es funcional.

En esta simulación se introdujo una entrada con cuatro escalones; dos de incremento y dos de decremento. Se ve en la gráfica que la red aprendió lo que se le entrenó. El entrenamiento fue basado en un escalón de incremento de 0 a 1 y después un escalón de decremento de 1 a 0.66. Durante el entrenamiento la red aprendió que a un cambio alto debe generar una salida con un 100 % de alcance, y para una entrada con un cambio pequeño debe alcanzar aproximadamente un 70 %.

En la gráfica de simulación se ve que para el primer escalón pequeño de 0.35, la respuesta de la red llegó a 0.2 y cuando se incrementó a 1, sí alcanzó su 100 % llegando a 1. Al decrementar con un valor pequeño sólo alcanzó aproximadamente el 70% y a 1 decrementarlo en forma mayor, produjo una respuesta que sobrepasó el 100 %.

La recopilación de datos fue un tanto escasa, debido a la restricción de tiempo que hay en una planta de producción, por lo que sólo se pudo entrenar a la red con dos cambios, deseando que hubiera sido mayor cantidad de cambios y en un más amplio margen.

4.6 *Diseño del Controlador Neuronal.*

Para diseñar un controlador por medio de red neuronal es necesario realizar la identificación inversa de la planta. En este punto es necesario entrenar a la red proporcionándole como entrada, las salidas de la planta, y como salidas deseables, las entradas a la planta. Con esta arquitectura, la red neuronal obtendrá como modelo, la entrada que se le debe proporcionar a la planta para que la planta genere la respuesta deseada, proporcionada originalmente al control con red neuronal.

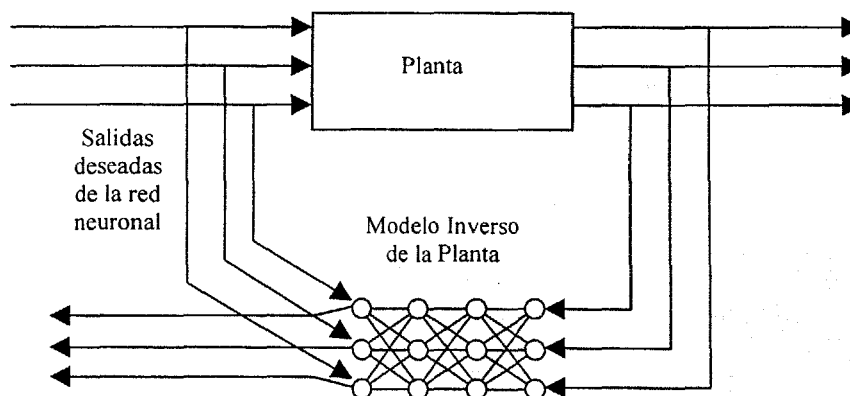


Fig. 17 - Identificación de modelo inverso de la planta

Una vez teniendo el modelo inverso del comportamiento de la planta, éste se coloca a la entrada a la planta. Al realizar lo anterior lo que hará la red inversa es proporcionar a la

planta la entrada tal para generar el comportamiento deseado proporcionado a la red neuronal. Obteniendo a la salida de la planta el mismo comportamiento proporcionado a la red inversa.




Fig. 18 – Control en base a una red neuronal

4.7 Desarrollo de la Red Neuronal para el Control de la Planta

Se desarrolló la red neuronal para generar el controlador utilizando el mismo esquema de red que se utilizó para la identificación. Se utilizó el mismo programa en Matlab que para la identificación, pero se intercambiaron las entradas por las salidas, generando el siguiente esquema. La única modificación dentro del programa para generar el controlador es que en los parámetros de diseño de la red se utilizó como error meta 0.1, el cual como quiera no fue alcanzado dentro del máximo número de épocas para realizar el entrenamiento; 5000 épocas, logrando alcanzar un error de 0.8513.

Al ejecutar el programa en Matlab se obtienen los pesos (ω) de la red junto con sus polarizaciones (b): ω_1 , b1, ω_2 , b2 (apéndice). La gráfica de la respuesta del controlador, al proporcionarle el comportamiento deseado, es la siguiente.

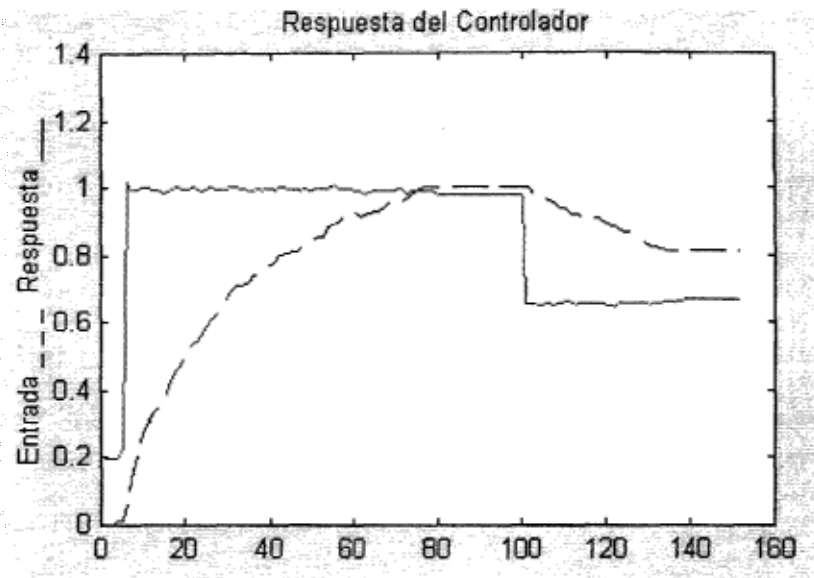


Fig. 19 – Respuesta del Controlador

La salida del controlador se representa en línea continua y la entrada en línea punteada. Lo que se le proporciona como entrada al controlador es la salida que se obtuvo del proceso al aplicarle los cambios en escalón, para esta entrada el controlador dará como salida los cambios en escalón que le fueron dados en un principio al sistema. Esto corresponde al proceso inverso al que se realizó para obtener la respuesta del proceso a los cambios en escalón (Fig. 12).

Aquí se obtiene de la salida del controlador, la entrada que se le proporcionará a la planta para que siga el comportamiento deseado (variable manipulada), el cual es el que se le aplica a la entrada del controlador.

Con este modelo del controlador se puede generar el controlador de la planta utilizando una computadora o PLC con algoritmos de programación de red neuronal, alimentando como red, el resultado del modelo del controlador.

5 Conclusiones

El presente trabajo sólo realiza la identificación de una parte del proceso existente en un alimentador de vidrio. Se realizó la identificación del comportamiento limitado de una zona del alimentador; zona del canal 2.

El resultado fue positivo logrando obtener una red neuronal, generando el comportamiento que se sigue en la zona analizada. Las simulaciones generaron resultados congruentes, pero sí se reconoce que son limitados, ya que se consideraron muchas constantes en el proceso.

El modelo obtenido en el presente trabajo sólo contempla una sólo entrada y una sólo salida, las cuales son el porcentaje de abertura del quemador para calentar la zona y la temperatura de salida. El trabajo realizado en la tesis podrá ser el inicio para futuros estudios de identificación más completos sobre la misma zona analizada.

Para llegar a obtener un modelo completo de la zona, es necesario tomar más entradas variables, como lo son la temperatura de entrada y el estiraje. Una vez teniendo el modelo completo de la zona, será necesario realizar la misma identificación en todas las demás zonas del alimentador.

Finalmente para llegar a tener un modelo completo del alimentador habrá que interconectar todas las redes neuronales obtenidas en el análisis de cada zona utilizando paquetes computacionales.

5.1 Descripción del Experimento

El experimento realizado en esta tesis fue hecho sobre una zona de un alimentador de vidrio para el formado de envases. La zona del alimentador donde se realizó el modelo neuronal fue el canal 2. Se trabajó sobre el canal 2 debido a que existe una zona anterior

en donde se puede estabilizar la temperatura de entrada a esta zona; se puede estabilizar la temperatura de salida del canal 1.

5.2 Adquisición de Datos

Para la obtención de datos, esta zona fue perturbada con cambios escalón en su calentamiento y se observó la variación que mostró en su temperatura de salida. Sólomente se realizaron dos cambios en su entrada, inicialmente se incrementó el calentamiento de la zona, abriendo el quemador en 15 puntos porcentuales; se cambió su abertura de 50 % a 69 %. Cuando la temperatura de salida del canal 2 logró estabilizarse, se decrementó la abertura del quemador en 5 puntos porcentuales; llegando a 64 %.

La temperatura del canal 2 fue originalmente de 1147 °C, la cual después de incrementar su calentamiento, llegó a estabilizarse en 1180 °C. Cuando el calentamiento fue disminuido, la temperatura de la zona se decrementó a 1173 °C.

5.3 Diseño de la Red Neuronal

La red neuronal diseñada fue del tipo de retropropagación y se consideraron 3 capas; una capa de entrada, una capa intermedia y una capa de salida. Cada una de las capas fue diseñada de la siguiente manera: 11 neuronas en su capa de entrada, 100 neuronas en su capa intermedia y una sóloa neurona en su capa de salida.

La selección de 11 neuronas en su capa de entrada fue debido a que se tomaron en cuenta, para el entrenamiento de la red, 5 retrasos de la entrada original y 5 retrasos de la salida, y unidos con la entrada original, suman las 11 entradas que se le proporcionaron a la red neuronal. Las 100 neuronas para la capa intermedia se seleccionó en base a pruebas que se realizaron durante el entrenamiento, se observó que con este número de neuronas, la red respondió en forma rápida y con poco error en sus resultados. La neurona de salida sóloamente fue una, ya que sólo existe una salida en el experimento realizado.

5.4 Resultados Experimentales

La red neuronal fue entrenada con la información obtenida de entrada (porcentaje de abertura del quemador) y de salida (temperatura de salida del canal 2) durante las perturbaciones en forma escalón. Para el entrenamiento se realizó una normalización de los datos de entrada y de salida, considerando los rangos de cambio en las variables involucradas en la identificación.

Los resultados que arrojó la red neuronal al ser entrenada fueron casi idénticos a los datos obtenidos del proceso real. Al aplicar a la red entrenada la misma entrada que al proceso real, los resultados fueron casi idénticos.

Después de realizar simulaciones y de analizar la respuesta de la red neuronal se concluyó que el modelo es funcional, debido a que las respuestas de la red tienden a seguir en forma exponencial a la entrada aplicada, forma similar a como responde el sistema real.

Sería importante verificar si los resultados obtenidos en la simulación se ajustan a los reales, aplicando a la planta real, la misma forma de entrada que se aplicó en la simulación. Esto nos ayudará a validar si el modelo es completamente funcional.

5.5 Trabajos Futuros

Lo obtenido en esta tesis es un modelo básico de la zona del canal 2 de un alimentador de vidrio, por lo que el siguiente paso para obtener un modelo completo de esta zona sería inicialmente modificar el punto de operación, realizar la identificación y hacer comparaciones con el primer modelo básico. Posteriormente incluir otras variables que pueden repercutir en la respuesta del proceso, como son el nivel de vidrio, el estiraje, el enfriamiento, entre otras, volver a generar la identificación y comparar con modelos anteriores. Al analizar las comparaciones se podría ir determinando qué variables

repercuten en el proceso y cuales no, por lo que se podrán realizar ajustes en cuanto a las variables incorporadas en la identificación.

Se logrará tener dominio del problema de variación de estirajes en alimentadores vecinos cuando se logre conjuntar los modelos de los alimentadores involucrados en un modelo general del juego de alimentadores existentes en el horno fundidor de vidrio.

Los resultados obtenidos durante esta tesis serán analizados para buscar optimizar los controladores de temperatura de alimentadores que existen en la actualidad. Esto se realizaría instalando, en un dispositivo electrónico, el modelo neuronal obtenido del alimentador, e interconectando este dispositivo con el controlador del alimentador para emular la interacción que existe entre el controlador y el alimentador real.

Los planteamientos anteriores podrán ser motivo de tema para tesis futuras.

Bibliografía

- [1] Michie, D., Spiegelhalter, D.J. y Taylor, C.C. "Machine Learning, Neural and Statistical Classification". Ellis Horwood. 1994.
- [2] Freeman, J.A. y Skapura, D.M. "Neural Networks. Algorithms, Applications, and Programming Techniques". Addison Wesley. 1992.
- [3] Box, G.E.P. y Jenkins, G.M. "Time Series Analysis Forecasting and Control". Holden-Day. 1970.
- [4] Owens-Brockway. "1992 Hot End Seminar". 1992.
- [5] Maki, Y. y Loparo, K.A. "A Neural-Network Approach to Fault Detection and Diagnosis in Industrial Processes". IEEE Transactions on Control Systems Technology, Vol. 5, No. 6, Noviembre 1997. p. 529-541.
- [6] Bloch, G., Sirou, F., Eustache, V. y Fatrez, P. "Neural Intelligent Control for a Steel Plant". IEEE Transactions on Neural Networks, Vol. 8, No. 4, Julio 1997. p. 910-918.
- [7] Gallant, S.J. "Neural Network Learning and Expert Systems". Massachusetts Institute of Technology. 1993.
- [8] Guedea, F. "Aplicación de Lógica difusa para Control de Temperaturas en un Alimentador de Vidrio". ITESM. 1996.
- [9] Levine, W.S. "The Control Handbook". 1996. p. 1033-1054.
- [10] Fukuda, T. y Shibata, T. "Theory and Applications of Neural Networks for Industrial Control Systems". IEEE Transactions on Industrial Electronics, Vol. 39, No. 6, Diciembre 1992. p. 472-489.
- [11] Levin, A.U. y Narendra, K.S. "Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization". IEEE Transactions on Neural Networks, Vol. 4, No. 2, Marzo 1993. p. 192-206.
- [12] Mejia, G. J. "Identificación de Sistemas Dinámicos Mediante Redes Neurales". ITESM. 1992.
- [13] García, F. A. "Modelación y Control de un Generador Sincrónico usado Redes Neuronales". ITESM. 1997.
- [14] Fuentes, M. "Redes Neurales - Aplicación a Identificación y Control de Sistemas". ITESM. 1990.

- [15] Miller, Sutton y Werbos. "Neural Networks for Control". 1991.
- [16] Fu, L. "Neural Networks in Computer Intelligence". 1994.
- [17] Lee, S.W. y Song, H.H. "A New Recurrent Neural-Network Architecture for Visual Pattern Recognition". IEEE Transactions on Neural Networks, Vol. 8, No. 2, Marzo 1997. p. 331-340.
- [18] Townsend, Neil y Tarassenko, L. "Estimations of Error Bounds for Neural-Network Function Approximators". IEEE Transactions on Neural Networks, Vol. 10, No. 2, Marzo 1999. p. 217-230.

Apéndice

A. Tabla de entrada aplicada y de salida obtenida del sistema.

Minuto	Entrada % de abertura del quemador	Salida Temperatura °C
0	54.02	1146.96
1	54.02	1146.96
2	54.02	1146.96
3	54.33	1147.29
4	69.40	1147.29
5	69.43	1149.17
6	69.40	1151.39
7	69.43	1152.99
8	69.43	1154.48
9	69.43	1155.87
10	69.43	1156.58
11	69.43	1157.69
12	69.43	1158.19
13	69.43	1158.69
14	69.43	1159.35
15	69.43	1160.46
16	69.43	1161.40
17	69.43	1162.06
18	69.43	1162.56
19	69.43	1163.28
20	69.43	1164.16
21	69.43	1164.66
22	69.43	1164.88
23	69.43	1165.55
24	69.45	1166.49
25	69.45	1166.98
26	69.45	1167.48
27	69.45	1167.98
28	69.45	1168.37
29	69.45	1169.08
30	69.45	1169.75
31	69.45	1170.08
32	69.45	1170.47
33	69.45	1170.47
34	69.45	1170.85
35	69.45	1171.35
36	69.45	1171.35
37	69.45	1171.85
38	69.45	1172.07
39	69.45	1172.29
40	69.45	1172.79
41	69.45	1173.29
42	69.45	1173.29
43	69.45	1173.45
44	69.45	1173.68
45	69.45	1173.68
46	69.45	1174.17
47	69.45	1174.17
48	69.45	1174.40
49	69.45	1174.67
50	69.45	1174.89

Minuto	Entrada % de abertura del quemador	Salida Temperatura °C
51	69.45	1175.06
52	69.45	1175.06
53	69.45	1176.05
54	69.35	1176.28
55	69.38	1176.50
56	69.38	1176.77
57	69.38	1177.16
58	69.38	1177.16
59	69.38	1177.49
60	69.38	1177.16
61	69.38	1176.99
62	69.38	1177.16
63	69.40	1177.49
64	69.40	1177.66
65	69.40	1177.66
66	69.40	1177.88
67	69.40	1178.16
68	69.40	1178.38
69	69.40	1178.88
70	69.40	1178.88
71	69.38	1178.60
72	69.43	1178.88
73	69.40	1179.26
74	69.40	1179.59
75	69.40	1179.76
76	69.40	1179.98
77	69.40	1179.98
78	69.40	1179.98
79	69.40	1179.98
80	69.40	1179.98
81	69.40	1179.98
82	69.40	1179.98
83	69.40	1179.98
84	69.40	1179.98
85	69.40	1179.98
86	69.40	1179.98
87	69.40	1179.98
88	69.40	1179.98
89	69.40	1179.98
90	69.40	1179.98
91	69.40	1179.98
92	69.40	1179.98
93	69.40	1179.98
94	69.40	1179.98
95	69.40	1179.98
96	69.40	1179.98
97	69.38	1179.98
98	69.35	1179.98
99	64.22	1179.98
100	64.22	1179.98
101	64.22	1179.76

Minuto	Entrada % de abertura del quemador	Salida Temperatura °C
102	64.20	1179.26
103	64.22	1178.88
104	64.20	1178.88
105	64.18	1178.60
106	64.13	1178.38
107	64.15	1178.16
108	64.20	1177.88
109	64.22	1177.88
110	64.22	1177.66
111	64.22	1177.16
112	64.22	1177.16
113	64.20	1176.99
114	64.20	1176.99
115	64.18	1176.77
116	64.13	1176.77
117	64.08	1176.77
118	64.10	1176.50
119	64.13	1176.28
120	64.08	1176.05
121	64.22	1176.05
122	64.27	1175.78
123	64.27	1175.56
124	64.27	1175.39
125	64.30	1175.06
126	64.30	1174.89
127	64.30	1174.67
128	64.30	1174.40
129	64.30	1174.17
130	64.30	1174.17
131	64.30	1173.97
132	64.30	1173.97
133	64.30	1173.75
134	64.30	1173.68
135	64.30	1173.68
136	64.30	1173.68
137	64.30	1173.68
138	64.30	1173.68
139	64.30	1173.68
140	64.30	1173.68
141	64.30	1173.68
142	64.30	1173.68
143	64.30	1173.68
144	64.30	1173.68
145	64.30	1173.68
146	64.30	1173.68
147	64.30	1173.68
148	64.30	1173.68
149	64.30	1173.68
150	64.30	1173.68
151	64.30	1173.68

B. Tabla de entrada y de salida normalizadas.

Minuto	Entrada	Salida
0	0.0000	0.0000
1	0.0000	0.0000
2	0.0000	0.0000
3	0.0207	0.0101
4	0.9968	0.0101
5	0.9984	0.0670
6	0.9968	0.1340
7	0.9984	0.1826
8	0.9984	0.2278
9	0.9984	0.2697
10	0.9984	0.2915
11	0.9984	0.3250
12	0.9984	0.3400
13	0.9984	0.3551
14	0.9984	0.3752
15	0.9984	0.4087
16	0.9984	0.4372
17	0.9984	0.4573
18	0.9984	0.4724
19	0.9984	0.4941
20	0.9984	0.5209
21	0.9984	0.5360
22	0.9984	0.5427
23	0.9984	0.5628
24	1.0000	0.5913
25	1.0000	0.6064
26	1.0000	0.6214
27	1.0000	0.6365
28	1.0000	0.6482
29	1.0000	0.6700
30	1.0000	0.6901
31	1.0000	0.7002
32	1.0000	0.7119
33	1.0000	0.7119
34	1.0000	0.7236
35	1.0000	0.7387
36	1.0000	0.7387
37	1.0000	0.7538
38	1.0000	0.7605
39	1.0000	0.7672
40	1.0000	0.7822
41	1.0000	0.7973
42	1.0000	0.7973
43	1.0000	0.8023
44	1.0000	0.8090
45	1.0000	0.8090
46	1.0000	0.8241
47	1.0000	0.8241
48	1.0000	0.8308
49	1.0000	0.8392
50	1.0000	0.8459

Minuto	Entrada	Salida
51	1.0000	0.8509
52	1.0000	0.8509
53	1.0000	0.8811
54	0.9935	0.8878
55	0.9951	0.8945
56	0.9951	0.9028
57	0.9951	0.9146
58	0.9951	0.9146
59	0.9951	0.9246
60	0.9951	0.9146
61	0.9951	0.9095
62	0.9951	0.9146
63	0.9968	0.9246
64	0.9968	0.9296
65	0.9968	0.9296
66	0.9968	0.9363
67	0.9968	0.9447
68	0.9968	0.9514
69	0.9968	0.9665
70	0.9968	0.9665
71	0.9951	0.9581
72	0.9984	0.9665
73	0.9968	0.9782
74	0.9968	0.9883
75	0.9968	0.9933
76	0.9968	1.0000
77	0.9968	1.0000
78	0.9968	1.0000
79	0.9968	1.0000
80	0.9968	1.0000
81	0.9968	1.0000
82	0.9968	1.0000
83	0.9968	1.0000
84	0.9968	1.0000
85	0.9968	1.0000
86	0.9968	1.0000
87	0.9968	1.0000
88	0.9968	1.0000
89	0.9968	1.0000
90	0.9968	1.0000
91	0.9968	1.0000
92	0.9968	1.0000
93	0.9968	1.0000
94	0.9968	1.0000
95	0.9968	1.0000
96	0.9968	1.0000
97	0.9951	1.0000
98	0.9935	1.0000
99	0.6613	1.0000
100	0.6613	1.0000
101	0.6613	0.9933

Minuto	Entrada	Salida
102	0.6599	0.9782
103	0.6613	0.9665
104	0.6599	0.9665
105	0.6582	0.9581
106	0.6550	0.9514
107	0.6566	0.9447
108	0.6599	0.9363
109	0.6613	0.9363
110	0.6613	0.9296
111	0.6613	0.9146
112	0.6613	0.9146
113	0.6599	0.9095
114	0.6599	0.9095
115	0.6582	0.9028
116	0.6550	0.9028
117	0.6520	0.9028
118	0.6534	0.8945
119	0.6550	0.8878
120	0.6520	0.8811
121	0.6613	0.8811
122	0.6645	0.8727
123	0.6645	0.8660
124	0.6645	0.8610
125	0.6661	0.8509
126	0.6661	0.8459
127	0.6661	0.8392
128	0.6661	0.8308
129	0.6661	0.8241
130	0.6661	0.8241
131	0.6661	0.8181
132	0.6661	0.8181
133	0.6661	0.8114
134	0.6661	0.8090
135	0.6661	0.8090
136	0.6661	0.8090
137	0.6661	0.8090
138	0.6661	0.8090
139	0.6661	0.8090
140	0.6661	0.8090
141	0.6661	0.8090
142	0.6661	0.8090
143	0.6661	0.8090
144	0.6661	0.8090
145	0.6661	0.8090
146	0.6661	0.8090
147	0.6661	0.8090
148	0.6661	0.8090
149	0.6661	0.8090
150	0.6661	0.8090
151	0.6661	0.8090

C. Programa de Matlab para identificación.

```
clf;
figure(gcf)
colordef(gcf,'none')
setfs(600,250);
echo on
clc

%   DEFINICION DEL PROBLEMA
%   =====

load datentsal.txt;      % Entrada y Salidas anteriores
load datsal.txt;        % Salida a identificar

P = datentsal';
T = datsal';

[R,Q] = size(P);

%   DEFINICION DE LA RED NEURONAL
%   =====

S1 = 100;
[W1,b1,W2,b2] = initff(P,S1,'tansig',T,'purelin');
W2 = W2*0.01;
b2 = b2*0.01;

%   ENTRENAMIENTO DE LA RED
%   =====

df = 50;      % Cantidad de épocas en cada intervalo de la gráfica.
me = 5000;    % Máximo número de épocas en el entrenamiento.
eg = 0.01;    % Meta del Error Cuadrático Medio.
mc = 0.95;    % Constante Momentum.

tp = [df me eg NaN NaN NaN mc];

%   EMPIEZA ENTRENAMIENTO

[W1,b1,W2,b2,ep,tr] = trainbpx(W1,b1,'tansig',W2,b2,'purelin',P,T,tp);

%   FINALIZA ENTRENAMIENTO

%   SIMULACION
%   =====

A = simuff(P,W1,b1,'tansig',W2,b2,'purelin');

%   DISPLIEGUE DE RESULTADOS
%   =====

clf
time = 1:length(P);
plot(time,T,'--',time,A)
title('Respuesta de la Identificación')
xlabel('Tiempo (min)')
ylabel('Entrada _ _ _ Respuesta \_\_\_')
```

D. Pesos y valores de polarización de la Red de Identificación.

W1	1	2	3	4	5	6	7	8	9	10	11
1	-0.0985	0.2515	-0.1200	-1.1870	-1.2359	0.3201	-0.1703	0.9562	-0.4943	-0.0947	0.4522
2	0.6638	-0.3063	-0.3728	0.9381	0.7451	-0.7160	-0.4384	-0.2106	1.0297	0.7300	0.2763
3	-0.5093	-0.6496	-1.1911	0.3214	0.9429	-0.2223	-0.1637	0.3082	-0.9625	-0.4832	-0.3187
4	0.4629	-0.1193	-0.7932	-1.0277	-1.1397	0.4892	0.4521	-0.2719	0.2279	0.4975	-0.7054
5	-0.6020	0.3583	0.8211	0.3322	-1.0043	-0.1754	0.0309	0.8704	-0.0774	-1.0639	-0.5625
6	0.5632	-0.6747	0.3786	0.6705	-0.3334	-0.7648	1.3002	0.0713	0.5751	0.6620	-0.0487
7	0.5551	-0.0805	-0.4471	0.6785	1.1765	0.2289	-0.7953	0.7736	0.9031	-0.0784	-0.2514
8	0.5370	-0.0062	-1.0907	0.7089	0.7089	0.7760	0.1355	-0.2455	-0.7241	1.0241	0.4655
9	0.2772	-0.9637	-0.3279	0.0981	0.3853	0.8801	-0.0295	1.0466	-0.0855	-1.1020	-0.4052
10	0.9078	0.4942	0.4521	-0.0276	-0.0812	0.7147	-0.1901	-0.8711	0.7475	-0.8264	-0.8370
11	-0.6570	-0.8597	-0.3810	-0.1117	0.6381	0.8739	-0.0139	0.8568	-0.9035	0.4499	0.5237
12	-0.6851	-0.7734	-0.7362	0.2916	0.7455	0.6220	1.0819	0.4945	0.6007	0.3126	0.1229
13	0.6889	0.5978	-0.1833	-0.9118	0.0905	-0.2855	0.7055	0.3159	0.6381	0.9296	-0.9335
14	-0.9649	-0.6370	0.8041	0.0971	-0.8907	-0.9438	-0.8123	-0.1162	-0.4066	-0.0848	-0.0078
15	0.0938	-0.6041	0.3042	-0.7080	-0.4982	-0.9519	0.8332	-0.7920	-0.6430	0.0314	0.8182
16	-0.7554	-0.2524	-1.0843	-0.5608	0.2491	1.0645	0.7054	0.8169	-0.0138	-0.1844	-0.0955
17	0.2909	-0.0571	-0.2811	-0.6105	-0.9290	0.0316	-0.4548	1.3753	0.5415	-0.2469	0.8189
18	-0.5195	0.0232	-0.4952	0.8055	0.5828	-0.7220	0.5959	-0.9129	1.1114	-0.2797	-0.0209
19	-1.0080	0.3079	-0.8575	-0.2181	0.1206	-0.1945	-1.0865	-0.6142	-0.1497	0.8769	0.4827
20	0.0163	0.3004	-0.4566	0.0644	-0.8229	0.7882	0.1401	0.9807	-0.0064	0.7726	1.1603
21	0.6495	0.8300	-0.8393	0.7098	0.7181	-0.6043	0.4777	0.2981	-0.6783	0.6993	-0.2482
22	0.3678	-0.4479	-0.1990	-0.3845	-0.9475	-0.5674	-1.1427	0.3922	0.1735	1.0695	0.3884
23	-1.0844	-0.5358	0.4215	0.3317	-1.1753	0.7597	0.1378	0.0291	-0.1538	0.8797	0.0378
24	0.9029	0.3562	0.6453	-0.6511	0.3781	-0.4122	-0.5879	-0.9912	-0.6361	0.5508	0.6296
25	-0.8015	0.0214	0.6196	0.6924	-0.2396	-1.0168	0.8732	-0.6610	-0.8380	-0.1645	-0.0261
26	0.6875	-0.4712	-0.7117	-0.2841	-0.2546	0.9016	-0.5120	1.0073	0.9130	-0.1355	0.4868
27	0.2647	0.1873	0.1238	0.6573	0.9569	-0.7903	-0.5270	0.8577	-0.8625	-0.6536	0.5002
28	0.6390	0.5940	0.0462	-0.2903	0.8157	-0.2082	-0.3896	-0.8932	0.9173	-0.8954	0.6154
29	-0.8460	0.9677	0.9195	0.6011	-0.0570	-0.0305	0.5152	-0.0308	0.4183	-0.2716	-1.0719
30	0.3137	-0.1175	-0.1229	-0.7421	-1.0162	0.6545	-0.0070	-0.1768	0.9707	0.7127	-0.9521
31	-0.8234	-0.1641	-0.9731	-0.7519	0.6840	-0.2016	-0.9522	0.5832	0.5888	-0.4570	0.0026
32	-0.0518	0.9640	0.9025	0.2701	-0.8599	0.5727	-0.6004	-0.0237	-0.9705	-0.4199	-0.4052
33	0.3567	0.2223	-0.9467	-0.7912	-0.7976	-0.9354	0.4370	0.0439	-0.3397	-0.3365	-0.9463
34	-0.7255	0.8774	0.1023	0.8472	0.3883	0.9023	0.9360	0.5571	0.0867	-0.0475	0.5811
35	-0.0779	0.8950	0.9429	-0.0320	-0.7661	0.7710	0.4440	0.1982	-0.4200	-0.5948	-0.9393
36	-0.7457	0.5476	0.6930	-0.5858	-0.7695	0.8455	0.5240	-0.6500	0.3000	0.8031	-0.3304
37	0.2095	0.4882	0.3040	-0.5745	-1.1222	-0.6404	-0.7549	-1.0031	-0.3963	-0.4973	-0.4110
38	0.1581	-0.4630	0.4814	-0.8919	0.5367	-0.0433	0.6574	0.3925	1.1594	0.6726	0.7640
39	-0.4203	0.0991	0.7519	-0.8177	-0.7998	-0.3013	0.6380	0.8513	-0.2511	0.6769	-0.8504
40	-0.6197	0.3245	-0.1134	-0.6369	0.4641	-1.0496	0.7283	-0.3651	-1.1395	-0.5842	-0.0149
41	-1.0010	0.5565	-0.6686	0.7141	-0.5765	-0.4322	0.5306	-0.6699	0.6467	-0.7325	0.2346
42	-0.2518	-0.9747	0.2551	0.4943	0.2738	0.3844	0.8839	-0.9445	1.0548	-0.3466	-0.2754
43	0.6631	-0.9933	0.0472	0.5022	0.0341	1.1660	-0.2043	-0.4920	-0.4856	0.6010	-0.7783
44	0.1773	0.8157	-0.3193	-0.2754	0.1787	-1.0834	0.3738	-0.3891	-0.2850	-1.0984	0.9316
45	-0.2057	-0.7331	0.6116	-0.0451	-0.4761	0.7197	-1.1162	-0.2772	0.5550	0.0989	1.0894
46	-0.5314	-0.8087	0.5731	0.8154	0.6855	-0.4830	0.8414	0.7894	-0.1001	0.1017	0.7362
47	0.0286	-0.4402	-0.4266	0.6664	-0.9572	1.1740	-0.2062	0.5152	-0.9402	0.3986	-0.2482
48	0.5660	0.8421	0.2543	-0.2409	-0.5523	-0.6372	-0.4057	0.7415	1.3081	0.2221	0.4303
49	0.9027	-0.6522	0.6923	1.1234	0.7906	-0.6630	0.4130	0.2888	0.0888	0.4565	0.0983
50	0.5324	0.1924	-1.0275	-0.6676	1.0879	0.0551	-0.1243	0.3285	-0.8051	0.5856	-0.6366
51	0.9394	0.8048	0.6774	0.0555	-0.8206	0.1149	0.6449	0.4863	-0.7001	0.7546	-0.3698
52	0.7015	-0.3251	0.3493	0.0078	0.9043	0.6231	0.0563	-0.6734	0.6957	0.8922	-0.9304
53	-0.0313	-0.6518	0.6682	-0.0369	0.9358	-0.4682	-0.5374	0.2203	0.4611	0.8983	-1.0965
54	0.6987	-0.2350	0.7235	-0.2123	0.7945	-0.4287	-0.5956	0.6904	0.8630	-0.5571	0.8449
55	-0.9839	0.9744	-0.2299	0.0397	0.1288	-0.5332	0.1180	-0.6730	0.6467	0.9802	0.6385
56	0.2906	0.4613	-0.0605	0.6719	0.9590	0.1089	0.9821	0.6788	0.6006	0.8472	0.5754
57	0.7902	0.2551	-0.7333	-0.5185	-0.3235	-0.5066	0.8031	-0.7667	0.4691	-0.8378	0.7178
58	-0.8991	0.5526	0.8318	-0.2181	-0.4586	0.3234	0.4594	0.8915	0.7922	-0.4271	-0.7369
59	-0.4467	-0.0699	0.3720	-0.9459	-0.9147	-0.3985	-0.5782	-0.3807	-0.8272	-0.6505	-0.8419
60	0.5177	-0.7800	0.4120	-0.5685	-0.4870	-0.0874	-0.0092	-1.4423	-0.8400	0.3179	0.1509
61	0.1681	-0.3548	0.9675	0.6128	-0.4044	0.0119	-0.9614	0.5074	0.6852	-0.5665	-0.9621
62	-0.9930	0.6597	-0.0007	0.4159	-0.2226	0.4302	-0.4196	-0.4368	0.5550	1.1368	-0.8548
63	0.7471	0.2651	-0.1374	0.7535	-0.9172	-0.6046	0.4697	0.4241	-0.1867	-0.9514	-0.8746
64	-0.0293	0.3859	0.7951	-1.0103	-0.5135	-0.5470	0.7014	-1.0123	-0.4709	-0.1458	0.6346

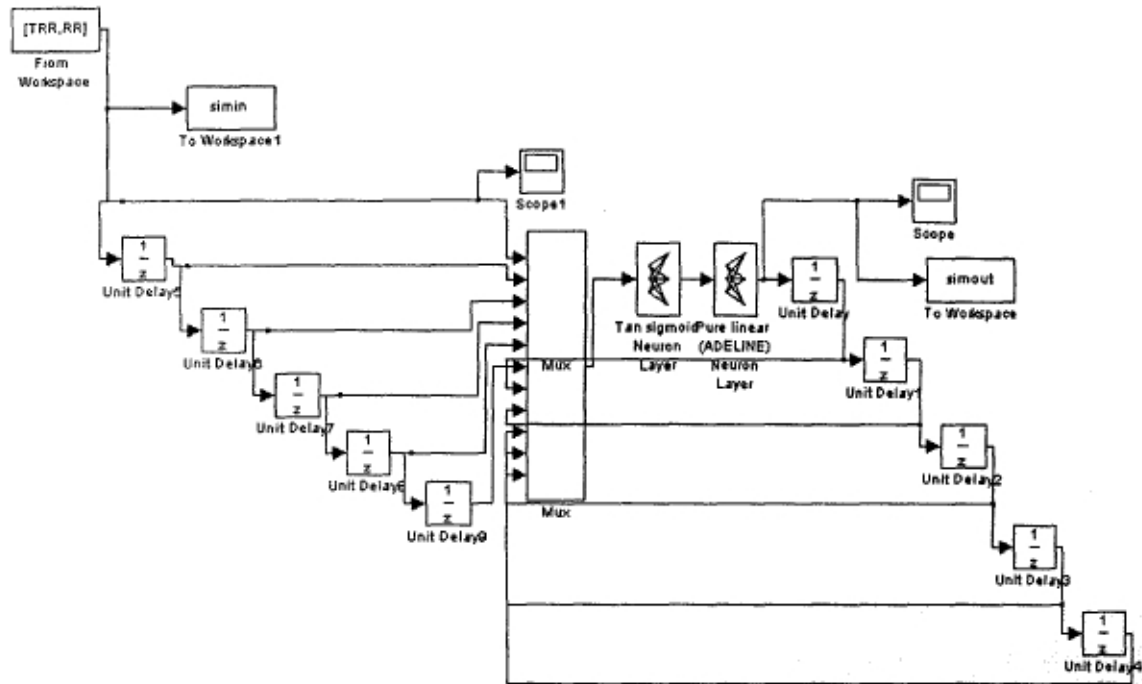
65	0.8334	0.0802	-0.8156	-0.0107	-0.5965	0.9076	-0.2121	0.7364	-0.0547	-0.7481	-0.9120
66	0.7331	1.1711	0.2757	-0.1946	0.1842	-0.7409	-0.2794	0.6103	-0.9923	0.3395	0.6099
67	0.3532	0.6388	-0.6354	-0.3520	0.8429	-0.8474	-0.5661	0.8434	-0.0132	0.5792	-0.8193
68	1.0761	-0.3955	-0.2314	0.9444	-0.5593	-0.1994	-0.9318	0.8494	0.0687	-0.5009	0.2641
69	-1.0706	0.7768	-0.6475	-1.1067	0.2984	0.4380	0.3323	0.8510	0.0329	0.0880	-0.0933
70	-1.0766	-0.1841	0.3951	-0.3316	0.0672	-0.9419	0.9834	0.5013	-0.8061	-0.5547	0.0307
71	0.5054	0.1814	0.8808	0.9247	-0.7342	-0.1916	-0.4088	0.7958	0.8611	-0.6300	-0.3067
72	-0.3551	-0.7329	-0.9394	-0.8237	-0.9434	0.3590	-0.0655	0.6113	0.0337	0.5310	-0.7895
73	-0.0930	-0.4587	0.8040	-0.4648	-0.4417	-0.4415	-1.1528	0.8450	-0.1028	0.7862	-0.6192
74	-0.3991	0.3024	0.4742	-0.9280	-0.3464	1.0515	-1.0296	0.3475	0.6874	0.5546	0.0633
75	-0.8266	0.6647	0.8102	-0.6473	0.8326	0.4338	0.0223	-0.5791	0.3943	-0.7659	-0.6054
76	-0.3474	0.9682	-0.8991	-0.7014	0.9188	-0.2068	0.4495	0.5911	0.2135	0.2363	-0.7932
77	-0.4807	-0.9113	-0.8640	-0.7710	-0.1250	-0.5770	-0.8821	0.4394	-0.8413	-0.3129	0.0052
78	0.9910	-0.7818	0.4811	0.0642	0.8736	-0.2004	0.9619	0.1294	-0.8595	0.1679	-0.4301
79	0.9340	-0.2237	0.7349	0.6041	-0.0075	-0.7959	-0.0060	0.5143	0.3124	0.9515	-0.8938
80	-0.3353	-0.8986	-0.5336	-0.1842	0.1056	-0.9714	0.4475	-0.5808	0.8392	0.0026	-0.0002
81	-0.5572	-0.5197	0.5117	0.8419	1.1484	-0.9532	0.7604	-0.0259	-0.1824	-0.2074	-0.3068
82	-0.9714	0.4269	-0.4856	0.7276	0.5271	-1.1238	0.0403	-0.1821	0.4980	0.7153	-0.5476
83	-0.4506	0.8331	-0.7252	-0.8523	0.2571	0.6344	0.0052	0.5139	-0.7460	0.6787	0.7935
84	0.9327	-0.2335	0.8718	0.3360	0.8421	-0.1992	0.5918	0.6119	-1.1166	0.0312	-0.0972
85	-0.3769	0.6896	-0.9068	-0.8318	-1.0067	0.6275	-0.5619	-0.5602	0.0184	-0.2362	-0.5470
86	0.1500	-0.7687	0.5005	-0.5936	-0.2808	0.6576	0.9217	0.2803	0.7683	0.8959	0.6872
87	-0.6334	0.6942	-0.7541	0.8238	-0.8169	-0.2102	-0.8274	-0.5398	0.6010	-0.4368	-0.3957
88	0.5704	-0.6413	-0.1352	-0.8526	-0.3969	0.7817	0.1027	0.2777	0.7175	0.6472	-1.1203
89	-0.7251	-0.8081	0.1724	-0.5461	-0.9197	-0.3033	0.7527	-0.4325	-0.5676	0.4245	0.9097
90	-0.2518	-0.3651	0.2954	0.7596	0.6835	-0.6557	0.7827	1.0641	0.4643	0.8981	-0.0439
91	0.8953	0.1857	0.0806	0.5264	-1.1742	0.0246	0.3246	0.6430	-0.7047	-0.9738	0.2555
92	0.8007	-0.8143	-0.6530	-0.9408	-0.1699	-0.6504	-0.5327	-0.0399	0.6425	0.8721	0.0365
93	0.6336	0.7296	0.3446	0.6322	-0.9253	0.1585	-0.2403	0.8832	-0.6508	0.1884	0.9468
94	-0.5762	-0.3865	-0.5849	-0.3417	0.4024	1.0892	-0.3682	-0.3150	-0.6660	-1.1066	-0.5727
95	1.0444	-0.0312	0.5794	-0.8859	-0.4515	-0.0860	-0.4866	-1.0911	-0.0930	-0.6869	0.4420
96	0.2245	-0.1480	-0.2164	0.0857	0.1295	0.6523	0.9652	0.9683	-0.9194	-0.8133	-0.7634
97	-0.9993	-0.6642	-0.2940	1.1738	-0.2087	-0.1862	0.0973	0.5289	0.2676	1.0558	-0.2634
98	-0.7493	1.0685	-0.1958	-0.1391	-0.7741	-0.5726	0.4469	0.2556	-0.6836	0.6930	-0.7919
99	0.7220	0.8774	-0.6601	0.0755	-0.8210	0.2535	0.7065	0.7441	0.8191	0.4960	-0.2937
100	0.9093	0.8521	0.7187	0.3768	0.2212	-0.2524	0.9242	-0.9263	-0.3657	0.5899	0.0949

b1							
1	-0.2643	26	-0.9771	51	-0.7906	76	-0.5352
2	-1.7407	27	-0.1468	52	-0.2292	77	1.7710
3	1.2515	28	-0.6448	53	0.0637	78	-1.6361
4	0.1563	29	0.0136	54	-0.7871	79	-0.5095
5	0.4157	30	-0.7714	55	-0.2667	80	0.8528
6	-2.1562	31	1.6422	56	-3.7647	81	-0.1923
7	-0.2743	32	0.8485	57	-0.1593	82	1.2310
8	-0.5157	33	2.9826	58	0.1069	83	-0.8889
9	0.3569	34	-2.4959	59	2.6350	84	-1.9642
10	0.0077	35	-1.1540	60	1.7537	85	1.9971
11	0.4906	36	-0.5826	61	-0.3050	86	-1.6890
12	-0.0206	37	2.5377	62	0.8482	87	1.0203
13	-0.9620	38	-1.2889	63	0.6710	88	-0.9833
14	2.7227	39	-0.6641	64	1.5987	89	0.6822
15	0.8397	40	2.4563	65	0.4272	90	-0.8021
16	-0.1156	41	0.7734	66	-0.0819	91	0.1201
17	0.5909	42	0.5952	67	-0.5985	92	1.3008
18	-0.4139	43	-0.4377	68	-0.7385	93	-1.0826
19	1.8265	44	0.9670	69	0.8966	94	2.2170
20	-0.4173	45	-0.3589	70	1.4043	95	0.1289
21	-0.4079	46	-0.4622	71	0.0724	96	-0.2664
22	1.3985	47	-0.7006	72	1.4716	97	-1.1723
23	0.5165	48	-1.7703	73	1.1871	98	1.5388
24	-0.5743	49	-1.5060	74	-0.0309	99	-0.7540
25	0.2203	50	0.6219	75	-0.8674	100	-1.9649

W2'							
1	-0.02010	26	0.02666	51	0.03016	76	-0.01116
2	0.02143	27	0.00530	52	0.04363	77	0.00551
3	-0.02019	28	-0.00544	53	0.01605	78	-0.01518
4	-0.01093	29	0.02451	54	0.01872	79	0.02577
5	-0.00792	30	-0.03631	55	0.00737	80	0.00475
6	0.05514	31	-0.01848	56	0.00515	81	-0.00795
7	0.02783	32	-0.04357	57	-0.01233	82	0.03663
8	0.00758	33	-0.02733	58	0.02510	83	0.02162
9	0.00792	34	0.00440	59	0.02801	84	0.01534
10	-0.01342	35	-0.03405	60	-0.02113	85	-0.01476
11	0.02832	36	0.00410	61	-0.03233	86	-0.00772
12	0.00135	37	0.00394	62	0.02817	87	-0.01159
13	0.02450	38	-0.01508	63	-0.00989	88	-0.01935
14	-0.03317	39	-0.02982	64	0.01138	89	-0.01360
15	-0.00637	40	-0.03724	65	-0.00670	90	-0.00970
16	0.02006	41	-0.01879	66	0.03583	91	-0.00039
17	0.03616	42	0.02845	67	-0.03725	92	0.01284
18	-0.01418	43	-0.03952	68	-0.02542	93	0.00325
19	-0.02041	44	0.00397	69	0.01862	94	-0.01140
20	-0.00828	45	-0.00931	70	0.00840	95	0.00260
21	0.02332	46	0.00657	71	0.04573	96	-0.00810
22	0.01525	47	-0.03454	72	0.00139	97	0.00137
23	0.01867	48	0.02221	73	0.01370	98	0.01109
24	-0.01728	49	0.01536	74	0.02285	99	-0.00365
25	-0.01910	50	0.00070	75	-0.04372	100	0.01564

b2
0.05369

E. Diagrama del Simulink para simulaciones.



Vita

Nicolás Flores Cardona nació en la ciudad de Monterrey, Nuevo León, México, el 7 de Enero de 1970. Recibió el título de Ingeniero en Sistemas Electrónicos en el Instituto Tecnológico y de Estudios Superiores de Monterrey Campus Monterrey en Diciembre de 1989.

En Abril de 1990 ingresa al Grupo Vitro en el negocio de Envases en la Dirección de Tecnología de Envases en el área de Tecnología Electrónica. Ha participado en conceptualización, diseño y desarrollo de sistemas de información de producción en tiempo real. En 1995 obtiene un Reconocimiento al Desarrollo Tecnológico por parte del Grupo Vitro.

En Mayo de 1999, el Ing. Nicolás Flores Cardona obtiene el grado de Maestro en Ciencias con Especialidad en Ingeniería de Control en el Instituto Tecnológico y de Estudios Superiores de Monterrey Campus Monterrey.

Sus áreas de interés son: control automático de procesos, tópicos de inteligencia artificial aplicados al control de procesos y sistemas de información de procesos.

Su dirección permanente es:

Cerezo 609
Residencial Real Cumbres
Monterrey, N.L., México
CP 64100
Tel. 306-0038

La presente tesis fue realizada con el paquete Microsoft Office en el ambiente Windows. Para la pruebas y simulaciones se utilizó el paquete Matlab. Microsoft Office y Windows son marcas registradas por Microsoft Corporation. Matlab es marca registrada de The Mathworks.