

64



# UNIVERSIDAD NACIONAL AUTÓNOMA DE MEXICO

FACULTAD DE INGENIERÍA

IMPLEMENTACIÓN DE UN CONTROLADOR PARA  
UNA PLANTA NEUMÁTICA, BASADO EN REDES  
NEURONALES

**T E S I S**  
QUE PARA OBTENER EL TÍTULO DE  
INGENIERO MECÁNICO ELECTRICISTA  
P R E S E N T A :  
EDUARDO ORTA TEJADA



DIRECTOR: ING. JUAN MANUEL GÓMEZ GONZÁLEZ

MÉXICO, D.F.

2000

285694



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## AGRADECIMIENTOS

A mi director de tesis Ing. Juan Manuel Gomez G.:

Por haberme platicado sobre las redes neuronales, y hacer un equipo de trabajo tan abierto y tan amable.

Al Dr. Jose Ismael Espinosa E.

Por ser y hacer activamente fomento de la Ciencia en México y por compartir tus conocimientos con los demas.

Al Ing. Soria Villegas

Por su apoyo en las actividades del departamento de control, y las facilidades brindadas para el desarrollo de la tesis.

Al Ing. Rafael Iriarte

Por la ayuda prestada con los aparatos de control utilizados en esta tesis.

A los que compartieron su tiempo;

en control Agustin A., Jose Luis, y Pedro L., y en cibernética a Javier, Roberto, Tere, e Irma.

A mis amigos y amigas de la Prepa 6:

A las familias Gonzales, Trejo y Tipacamú:

Porque me brindaron su compañía, amistad y un punto de equilibrio con la sociedad con la cual todos hemos tenido que avanzar a tientas con mayor o menor experiencia. Claudia G., Laura C., Elizabeth M., Gildardo T., Daniel T., Jorge S., Folke M., Carlos M., Jair D. Lisandro R., Cynthia Z.

A mis amigos y amigas:

Por compartir conmigo los momentos más difíciles de la carrera.  
Georgina L., Ana Luz A., Carolina N., Rafael, Gildardo T.

## **DEDICATORIA**

A mis padres Eduardo Carlos Orta G. y Silvia Lilia Tejada C.:

Por haberme dado la libertad para alcanzar mis metas, con amor, dandome una educación activa, les dedico esta tesis ya que a sido el fruto de la dedicación, entereza, constancia, largas noches de desvelos, y de grandes sacrificios, que juntos hemos conseguido afrontar, llegado el dia en que me veran cumpliendo este hanelo que esta escrito generación tras generación y que cumple un ciclo de la formación profesional.

Les dedico esta tesis por haberme hecho una persona capaz y conciente de las largas jornadas que tuvieron que invertir junto a mi y a mi hermano haciendo tareas, y corriendo de un lado al otro para conseguir las mejores oportunidades, de vida y diversión, y especialmente en aquellos momentos donde hacia falta la salud y permanecieron junto a mi cuidando cada detalle y cada uno de los sintomas para aminorar el dolor y las depresiones de la convalecencia.

La distancia entre la razon y los sentimientos se volcan simultaneos y atropellan mi pensabiento conduciendo a la terquedad del presente, viviendo la gesta heroica de la insertidumbre que rompe el silencio y desnuda las verdades sospechosas. Una ultima y angustiosa hora en la que todo se hace nubloso y transita solo los cuatro puntos cardinales que forman la familia y que cada uno indica la dirección del movimiento perpetuo, para avanzar, crecer y ser flexibles cuando los vientos arrecian y haber mantenido un lugar de socio y un escondite de los elementos.

A mi hermano Carlos Orta T.:

A quien le agradezco su compañía y apoyo en las horas de estudio, y de juego, por compartir tus momentos con migo.

A la memoria de mi abuelo Zoilo Tejada, y

A mi abuela Concepción Castañeda, y

A mis Tios Zoila Tejada y Hector Rojas,:

Por haber contribuido en mis estudios hechandome porras cuando habia que hacerlo.

A mi amigo y director de tesis Juan Manuel Gomez G.:

Por haberme dirigido con paciencia, durante estos largos años de conocernos y de compartir experiencias.

---

**A** principios de siglo surgieron grandes cambios en la investigación acerca del sistema nervioso central y periférico, debido al uso del microscopio óptico, pero también en campos afines como la psicología hubo grandes avances específicamente tomemos un fragmento del discurso de IVAN PAVLOV (1849-1936) para describir el tratamiento matemático que constituye la formación de las redes neuronales artificiales, de su discurso pronunciado en Moscú en 1909:

“ De este modo, toda la vida, desde los organismos más simples a los más complicados - incluido el humano -, es una larga serie de sistemas de equilibrio, cada vez más complejos, con el mundo exterior. Llegará el día - quizás todavía lejano - en que el análisis matemático, apoyándose en las ciencias naturales, encuadrará todos estos equilibrios en las fórmulas grandiosas de sus ecuaciones, donde encontrará también expresión su propia existencia.”

## INDICE

<b>CAPITULO I. Introducción</b>	<b>2</b>
1.1.- Neurona Biológica	2
1.2.-. Redes Neuronales Biológicas	3
1.3.- Planteamiento del problema	3
<b>CAPITULO II Aprendizaje de las Redes Neuronales Artificiales</b>	<b>4</b>
II.1.1.- Retropropagación	4
II.2.1.- La función Sigmoidal	5
II.2.2.- Regla Delta	7
II.2.3.- Error	8
<b>CAPITULO III Implementación de la red neuronal</b>	<b>8</b>
III.1.- Resultados	13
III.1.1 Enfoque de Control Lineal	13
III.2.- Modelo Digital	14
III.2.1.- La Plantilla	15
III.3.- Diseño e Implementación del controlador PID	29
III.4.- Plantilla Mejorada	32
<b>CAPITULO IV Discusión</b>	<b>41</b>
IV.1.1.- Análisis del centro de la escala.	50
IV.1.2.- Plantilla entrada-salida No útiles para el análisis gráfico	51
IV.1.3.- Plantilla entrada-salida útiles para el análisis gráfico	51
IV.1.3.1.- Primer Caso	52
IV.1.3.2.- Segundo Caso	52
IV.1.3.3.- Tercer Caso	52
IV.1.3.4.- Cuarto Caso	53
IV.1.3.5.- Quinto Caso	54
IV.1.3.6.- Sexto Caso	54
IV.1.3.7.- Séptimo Caso	55
IV.1.3.8.- Octavo Caso	55
<b>CAPITULO V Valores Finales Ideales</b>	<b>56</b>
V.2.1.- Valor de presión final 0.25 bar	56
V.2.2.- Valor de presión final 0.5 bar	56
V.2.3.- Valor de presión final 0.75 bar	56
V.2.4.- Valor de presión final 1 bar	57
V.2.5.- Valor de presión final 1.25 bar	57
V.2.6.- Valor de presión final 1.5 bar	57
V.2.7.- Valor de presión final 1.75 bar	57
V.2.8.- Valor de presión final 2 bar	58
V.3.- Neurocontroladores de mayor campo de Medidas	59
V.3.1.- Primer Intervalo	60
V.3.2.- Segundo Intervalo	62
V.3.3.- Tercer Intervalo	63
<b>CAPITULO VI CONCLUSIONES</b>	<b>65</b>
VI.1.- BIBLIOGRAFÍA	66

Hoy en día encontramos redes neuronales artificiales en campos donde tradicionalmente era difícil conseguir una solución matemática en un corto plazo o donde el grupo de sistemas interconectados no arrojaban un modelo identificable, de acuerdo con la teoría de las redes neuronales y en particular de redes donde se involucra la variable tiempo, la única condición para el análisis de sistemas es la presencia de dos señales, una señal de entrada y una señal de salida. A partir de esta premisa las redes neuronales son capaces de suplir cualquier elemento controlador, involucrado en el proceso, pero también es capaz de predecir o actuar adaptivamente, en una estructura en retropropagación típica, o en una prealimentación donde el controlador actúa por anticipado. Las redes Neuronales Artificiales establecen diferencias de genero con otro tipo de estructuras normalmente utilizadas para el control de sistemas, una de ellas se refiere a la capacidad de tolerar ruidos internos y/o externos, debido a su capacidad de generalización y auto corrección, aunado a que la relación que se establece entre la entrada y la salida de la red neuronal es la suma de reacciones individuales limitadas o reforzadas por un umbral de certidumbre, capaz de nulificar las condiciones ruidosas o extrañas al proceso y acentuar las condiciones mas favorables al proceso. La interpretación de esta capacidad también es conocida como la de discriminación entre una dinámica donde los sucesos no son predecibles por modelos matemáticos lineales, sino por el contrario, la red neuronal actúa como efectos encadenados que pueden ser interrumpidos cuando los efectos desaparecen, al perderse las conexiones que refuerzan dichos efectos. Hasta el momento el limite de las redes neuronales tiene que ver con la estructura seleccionada para trabajar en un sistema, donde el tiempo de respuesta real debe ser inferior al tiempo de calculo del sistema, y esto conlleva a una dependencia con las estructuras de diseño del hardware, que por otro lado es la tecnología que reporta los mas grandes avances de nuestro tiempo.

### 1.- NEURONA BIOLÒGICA

Uno de los dogmas de la neurociencia, fue planteado por Ramón y Cajal y Sherrington al finalizar el siglo pasado, en el que la neurona tenia una función organizativa simple, en el que las dendritas recibían entradas sinápticas, y el axon enviaba la salida de la neurona, por medio de impulsos que atravesaban el axon y activaban las salidas sinápticas en las terminales del axon. Este sencillo plan, en el que las entradas provenían de las dendritas y las salidas iban por el axon, fue aceptado como la ley dinámica de polarización de Cajal. Era atractivo porque implicaba que la neurona tenía elementos de entrada- salida similares, y que la organización nerviosa consistía en enganchar un gran número de estos elementos de manera apropiada.

---

## 2.- REDES NEURONALES BIOLÓGICAS

Llamamos red neuronal biológica a la conexión de miles de neuronas conectadas unas con otras donde cada una de ellas esta compuesta como una célula biológica, con cuerpo celular (soma), un conducto denominado axón y ramificaciones denominadas dendritas.

Existiendo diversos tipos de interconexiones entre neuronas como son, las axo axónica, axo somáticas, y las axo dendríticas, que reciben las señales de entrada; el cuerpo celular las combina e integra y emite señales de salida hacia otros punto de conexión sinápticos.

Existen dos tipos de sinapsis: a) las sinápsis excitadoras, cuyos neurotransmisores provocan disminución de potencial en la membrana de la célula postsináptica, facilitando la generación de impulsos a mayor velocidad, y b) las sinapsis inhibitorias, cuyos neurotransmisores tienden a estabilizar el potencial de la membrana, dificultando la emisión de impulsos. En cada instante, algunas de las sinapsis estarán activas y otras se hallarán en reposo; la suma de los efectos excitadores e inhibidores determina si la célula será o no estimulada; es decir, si emitirá o no un tren de impulsos y a qué velocidad.

## 3.- PLANTEAMIENTO DEL PROBLEMA

Partiendo de un algoritmo de entrenamiento conocido y bien probado como es el algoritmo de retropropagación, se ha planteado aplicarla a un sistemas no lineal como es el caso de un compresor cuya capacidad máxima es 2 bares, de presión.

Haciendo uso de las técnicas de control lineal como base de conocimiento para la obtención de patrones dinámicos del compresor cuyo campo de medidas esta dado en 0 a 2 bares de presión y con lo cuál habremos de generar patrones de entrenamiento dinámico para el entrenamiento de los controladores mediante redes neuronales.

El algoritmo de retropropagación consistirá en fijar una red neuronal compuesta por una capa de entrada, una o varias capas intermedias y una de salida, en el proceso de entrenamiento de la red, se calcularan los pesos con los que se conectan las neuronas de la capa intermedias o de salida, este proceso se repetirá hasta que la respuesta de la red sea la deseada a las entradas presentadas y es entonces cuando se conectara a la planta a controlar.

Los resultados de comparar los sistemas lineales y no lineales fueron sorprendentes, mientras que la respuesta lineal se ajusta al comportamiento conocido de los controladores P, PI, PID.

La respuesta no lineal se a hecho considerar una malla de trabajo cuyos puntos de cruce fueran denominados variables de prueba del sistema. Se obtuvieron cambios de comportamiento a la salida del compresor controlado de acuerdo a una bien planeada secuencia de datos de entrada.

Final mente la acción de estas variables controlan a su modo el compresor para mejorar las características de respuesta lineal, y permitir un sistema de búsqueda de propiedades de control no lineal, donde se pueden separar las redes neuronales bien comportadas de las mal comportadas separándolas en grupos de estudio.

Los resultados de cada grupo a sido medido de acuerdo con el valor final, de la señal, optimizando el tiempo de levantamiento y reduciendo drásticamente el período de transientes normalmente encontrados en la respuesta a un controlador lineal.

## II. APRENDIZAJE EN LAS REDES NEURONALES ARTIFICIALES

El aprendizaje en redes neuronales puede ser supervisado y no supervisado, el aprendizaje supervisado se refiere a que la red tiene una entrada conocida durante el entrenamiento que le dice cual es la respuesta correcta que deberá aprender (Ver figura 1).

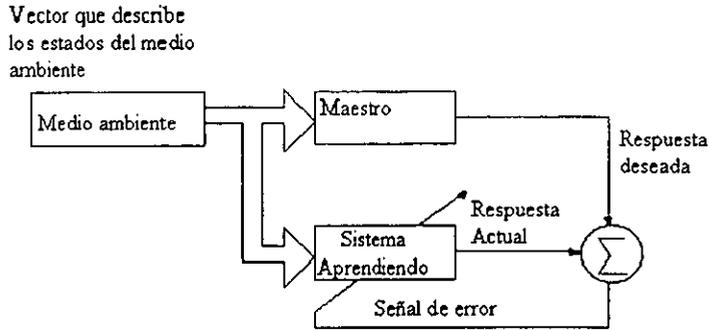


Figura:1 Aprendizaje Supervisado

El algoritmo de aprendizaje entonces contiene los medios para determinar si el resultado de la red ha sido correcto o incorrecto y sabe como ajustar los pesos. El aprendizaje no supervisado se refiere a que la red no tiene este conocimiento de la respuesta correcta y así no puede saber exactamente cual debería ser tal respuesta correcta.

### II.- Aprendizaje Supervisado

#### 2.- Redes solo con propagación en adelante

- a) Perceptron
- b) Adaline, Madaline
- c) Retropropagación (BP)

## II. RETROPROPAGACIÓN

El aprendizaje implica que el elemento procesador de alguna forma cambia su comportamiento de entrada o salida en respuesta al medio ambiente. Por ejemplo, si el elemento procesador originalmente tenia una salida de +1 en respuesta a un patrón particular de entrada, puede tener una salida de -1 debido al mismo patrón de entrada después de que se ha generado el aprendizaje. El elemento procesador de alguna forma cambia su salida dependiendo de la respuesta correcta que deberá tener a la entrada. La salida es calculada como resultado de la función de activación de la entrada pesada. La entrada de la red para este caso se calcula multiplicando el valor de cada entrada individual por su peso sináptico correspondiente o, equivalente, tomando el producto punto del vector de entrada con el de pesos. El elemento procesador toma la suma de entradas y las aplica a la función de activación para calcular la salida resultante.

Normalmente, aun que no siempre, la función de activación para un elemento procesador dado se fija al momento de construir la red. De forma tal, que si queremos cambiar el valor de salida, debemos hacer algo para cambiar no la función de activación pero si la entrada pesada.

**II.1.1.2. La función sigmoïdal** (Figura 2); es la más común de las funciones empleadas en la construcción de redes neuronales. Con una forma de S característica, contiene un incremento monotónico, y aproximación asintótica a valores fijos mientras que la entrada se aproxima a más o menos infinito (ecuación 1, 2).

$$\phi(v) = \frac{1}{1 + e^{-av}} \dots (1)$$

donde "a" es el parámetro de la pendiente en la función sigmoïdal. Al variar el parámetro "a", obtenemos sigmoïdes de diferentes pendientes como se muestra en la figura 3:

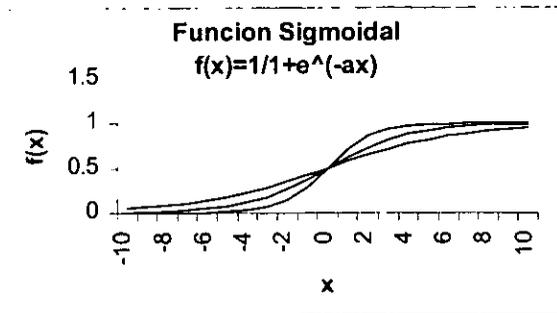


Figura: 2, donde a=0.9, a2=0.5 y a3=0.3 Función sigmoïdal

De echo, la pendiente en el origen es a/4. En el límite, el cuál aparenta aproximarse al tender a infinito, la función sigmoïdal se comporta como una función de umbral. Aún así, La función de umbral asume valores de 0 a 1. Nótese además que la función sigmoïdal es diferenciable, en comparación a la función de umbral no lo es. Algunas veces es deseable tener una función de activación de -1 a 1, en tal caso la función de activación asume una antisimetría con respecto al origen. Específicamente para la función de umbral se define como

$$\phi(v) = \begin{cases} 1 & \text{si } v > 0 \\ 0 & \text{si } v = 0 \\ 1 & \text{si } v < 0 \end{cases}$$

llamada también función de signo. La función sigmoïdal puede usar la función tangente hiperbólica que se define como (ecuación 2):

$$\phi(x) = \tanh\left(\frac{v}{2}\right) = \frac{1 - e^{-v}}{1 + e^{-v}} \dots (2)$$

Permitir que la función de activación de tipo sigmoide asuma valores negativos tiene beneficios analíticos. Por lo que se puede ajustar la primera sigmoide presentada por unos límites (-1,1) con:

$$\phi(v) = \frac{1}{1 + e^{-av}} \dots (1)$$

$$f(x) = \text{Sigmoide}(x) = \min + (\max - \min) \phi(x)$$

donde

$$\min = -1$$

$$\max = 1$$

$$\text{pendiente "a"} = 1$$

A partir de que el elemento procesador no tiene control sobre el patrón de entrada, ya que solo reacciona no crea el medio ambiente. La única forma es cambiar la entrada pesada al modificar los valores de los pesos en las entradas individuales. Así la red aprende al cambiar los pesos a la entrada. Las leyes de aprendizaje para una red específica definen precisamente como cambiar los pesos en respuesta a la entrada recibida y al patrón de salida asociado, denominado par entrada, salida.

Retropropagación es una abreviatura de la ley de aprendizaje de retropropagación del error. El término retropropagación produce confusión. Estrictamente hablando, la retropropagación es el método computacional para calcular el gradiente negativo del error de la red con topología en adelante, una forma directa y elegante para aplicar la regla de la cadena en el cálculo elemental (Werbos 1994). Por añadidura, la retropropagación se refiere al método de entrenamiento que utiliza retropropagación para calcular el gradiente. Además, la red en retropropagación tiene topología en adelante entrenada por retropropagación.

Las contribuciones para el desarrollo de las redes neuronales en retropropagación de McCulloch y Pitts (1943), quienes describen el cálculo lógico de las redes neuronales [1],[2],[3],[4],[5],[6], Rosenblatt (1958) introducen su trabajo en el Perceptron. Años después Widrow y Hoff (1960) introducen la Adaline [1],[10]. Como es bien sabido la diferencia entre el Perceptron y la Adaline recae en el proceso de entrenamiento, el algoritmo del error mínimo cuadrado (LMS). Para (1969) Minsky y Papert comienzan el estudio del perceptron multicapas [11],[12], debido a las limitaciones del perceptron de una capa. Los trabajos continuaron y Cowan (1967) introduce la sigmoide [13] siendo el mismo año en que Grossberg (1967 y 1968) introduce el modelo aditivo de neurona [14]. La tesis doctoral de Werbos en la universidad de Harvard en agosto de 1974, es la primera que introduce el gradiente eficiente computacional en modo invertido [16], que se aplico a los modelos generales de redes, para casos particulares. El aprendizaje en retropropagación se descubre al mismo tiempo por (Parker 1985) [17] y (Le Cun 1985) [17]

Retropropagación es el nombre tomado para la regla delta generalizada, el algoritmo de entrenamiento que fue popularizado por Rumelhart, Hinton y Williams en su capítulo 8 de Rumelhart y McClelland (1986) que continua siendo utilizado con mayor frecuencia como el método de aprendizaje supervisado por redes neuronales. La regla delta generalizada (incluyendo el momentum) es llamada el método de la pelota pesada en la literatura del análisis numérico (Poljak 1964, Bertsekas 1995)

La retropropagación estándar, puede emplearse como incrementos (en línea) del entrenamiento (en la que los pesos son actualizados después de procesar cada caso) pero no converge a un punto estacionario de la superficie del error. Para obtener la convergencia, la tasa de aprendizaje debe ser reducida lentamente. Esta metodología es llamada aproximación estocástica.

La propiedad de converger de la retropropagación estándar, la aproximación estocástica, y los métodos relacionados incluyen algoritmos por incremento y por lote, discutidos claramente por Bertsakas y Tsitsiklis (1996).

El procesamiento por lote, no hay razón para sufrir por la lenta conversión y el tedioso ajuste de la tasa de aprendizaje y el momento de la retropropagación estándar. La mayoría de la literatura en investigación de las redes neuronales trata de aumentar la velocidad de la retropropagación. Dos de los métodos conocidos son Quikprop (Fahlman 1989) y RPROP (Riedmiller 1993).

### II.2.1.3 REGLA DELTA

Al utilizar el algoritmo de Aprendizaje desarrollado por Bernard Widrow y Ted Hoff en la Universidad de Stanford, la regla delta o la ley de aprendizaje (LMS) utiliza el algoritmo del error mínimo cuadrático. La red con la cual se aplica este algoritmo por primera vez, es la ADALINE la cuál evoluciona a la MADALINE en 1963. Necesitamos una regla que nos diga como cambiar los pesos sinápticos dependiendo en si nuestra clasificación haya sido o no correcta. Primero tenemos que modificar el elemento procesador para que pueda monitorear su propia salida. Luego permitámosle comparar su salida con la salida deseada  $I_0$  y calcular el valor del error  $E$ , para este patrón de entrada.  $E$  es calculado al restar la actual salida  $Y$ , de la respuesta  $I_0$ ,  $E = I_0 - Y$ . Finalmente, calculamos como cambia el peso utilizando la regla delta (ecuación. 3).

$$W_{nueva} - W_{vieja} = \frac{\beta EX}{|X|^2} \dots (3)$$

donde  $X$  y  $W$  son los vectores de entrada y el peso, respectivamente. La constante  $\beta$  es una constante de aprendizaje que elegimos después. Note que la regla delta es una ecuación vectorial - no escalar -. El error  $E$  y la constante  $\beta$  son valores escalares, los demás son vectores, es decir  $W$  y  $X$ . Al calcular el error actual, vemos que tan lejos estamos del valor ideal. para los pesos de esta entrada. Entonces ajustamos el vector de pesos calculando un vector Delta que es paralelo al vector de entrada y tiene una magnitud descrita por la ecuación anterior. Este proceso tiene una interpretación geométrica simple. Si podemos demostrar matemáticamente que el agregar el error medio cuadrático es una función del vector de pesos, específicamente ésta función es una función cuadrática del vector de pesos. Así pues, si dibujamos el error medio cuadrático contra el vector de pesos posible tendríamos una parábola (en realidad un hiperparaboloide) ya que en general se hace en un  $n$ -espacio. La regla delta mueve el vector de pesos desde el lugar donde esté en la superficie parabólica hacia el fondo de la cazuela. Esto lo hace al moverse siguiendo el gradiente negativo de la parábola, que es una ruta más directa al fondo de la cazuela. La constante  $\beta$  mide la velocidad de convergencia del vector de pesos y se recomiendan valores superiores a (0.1 y 0.2) e inferiores a (0.8 y 0.9).

## II.2.2 ERROR

Distingase el error en el método de control lineal que consiste en obtener una señal que afecta al controlador lineal de la señal de error empleada para entrenar el sistema de control no-lineal. aparentemente dichas señales en principio son idénticas ya que al presentarse dentro de una configuración de control en lazo cerrado, la acción ejercida por la señal de error alimentando el controlador lineal nos sirve para obtener una señal de control a la salida de este. Con el procedimiento de muestreo que se verá más adelante se adquieren ambas señales como un par de señales de entrenamiento para la red neuronal artificial, es entonces y solo entonces cuando dicha señal de error adquiere otro significado. Toda experiencia previa con sistemas lineales sería útil para el análisis de esta nueva señal de error que será modificada a través del controlador no-lineal, generándose una nueva señal de error con características totalmente diferentes de la señal lineal, debido a que el controlador no-lineal tratara de aprender del error calculado linealmente y de la respuesta del sistema de control lineal las primeras señales de error no-lineal son comparables con las señales de error lineal, sin embargo a medida que desarrollamos un conocimiento general del comportamiento de la red neuronal podremos modificar substancialmente esta señal para obtener mejores resultados no-lineales en direcciones imprevistas de diseño particular de esta señal, junto con la señal de salida del compresor que funciona como par de entrenamiento de una red neuronal artificial.

### III. IMPLEMENTACIÓN DE LA RED NEURONAL.

Con objeto de conocer el comportamiento dinámico del compresor de presión, establecimos un método de análisis conocido por el lugar geométrico de las raíces, de acuerdo con este abríamos de conocer la función en el tiempo y la frecuencia del sistema. Los inmediatos resultados nos permitieron saber que el tipo de sistema al que nos enfrentábamos, corresponde a un sistema no lineal de orden mayor, con lo cual hemos de proponer un control capaz de adaptarse a las condiciones de no linealidad y que superase con tal razón las características de origen presentadas por la acción lineal de un controlador PID. Las acciones de control previstas en esta tesis comienzan con el control de lazo abierto. La respuesta de lazo abierto producía una constante  $T = 12.3s$  cuando la función alcanza el 63.3% de su valor final, con una referencia de entrada de 8 V y un valor final de  $12.5cm * 500 mV / cm = 6.25V$ .

**Las características de lazo cerrado conducían a:**

**Tiempo pico =** 21.6s.

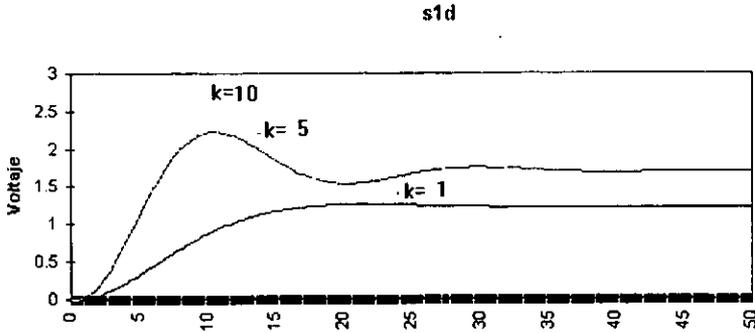
**Ganancia de lazo =** 27.79max.

**Error en estado estable =** 4.6855V

Con lo cual se calculo un modelo que nunca llego a parecerse

$$G_p(s) = \frac{0.253764}{(S + 0.17)(S + 0.172969)(S + 1.26)} \dots(4)$$

poco después se comprobó que el modelo matemático no podía ser resuelto linealmente ya que ningún modelo obtenido por el Tool Box de identificación de Matlab, no pudiera conseguir un modelo lineal.



**Gráfica del comportamiento del modelo matemático a cambios en la ganancia del sistema de control en retropropagación.  $k=[1,5,10]$**

Figura 3. Modelo matemático.

Con estos resultados fue posible diseñar un modelo digital el cual podía generar una respuesta ideal para las condiciones del sistema de lazo cerrado y con el cual se obtuvieron algunos grupos de datos para el estudio de las señales de control, de error y de salida del sistema haciendo uso de un controlador proporcional como parte del análisis (Ver figura 3). El grupo de datos calculados en base a la siguiente simulación conformaron los primeros archivos de trabajo fuera de línea necesarios para entrenar una red neuronal. Para éste caso se tomó el modelo discreto con una frecuencia de muestreo  $f=4\text{hz}$  y del cual se tiene:

$$G_p = \frac{5.9873 \times 10^{-5} (Z^2 + 2.1699 \times 10^{-4} Z + 0.8183634)}{(Z - 0.7297889)(Z - 0.9583905)(Z - 0.95744)} \dots (5)$$

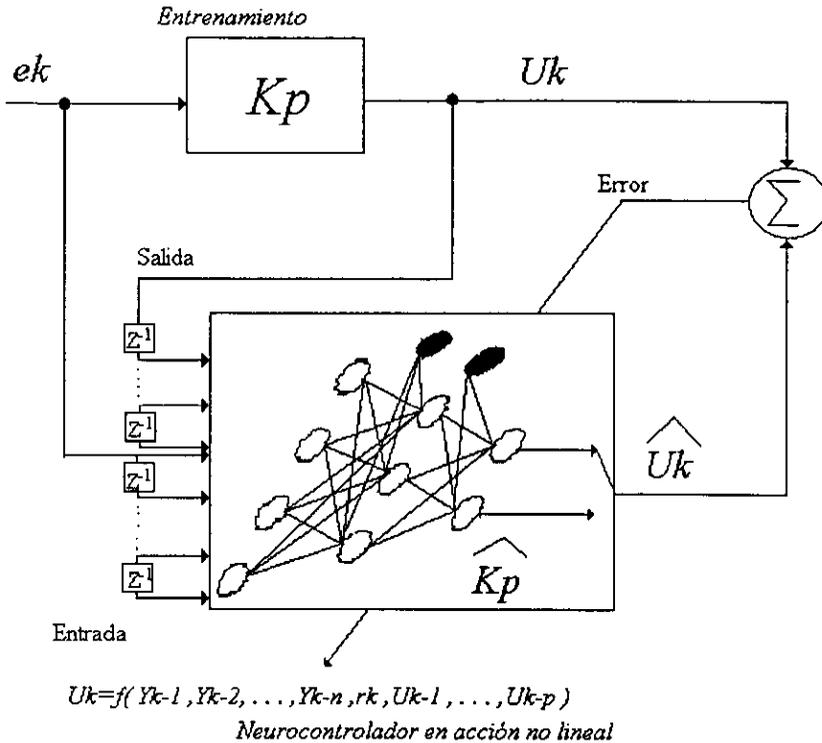
$$G_p(Z) = \frac{5.9873 \times 10^{-5} Z^2 + 2.16993 \times 10^{-4} Z + 0.8183634 \times 10^{-5}}{Z^3 - 2.645619 Z^2 + 2.315753 Z - 0.6696553} \dots (6)$$

$$\begin{pmatrix} X_1^2 \\ X_2^2 \\ X_3^2 \end{pmatrix} = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0.6696553 & -2.315753 & 2.645619 \end{pmatrix} * \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} + \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} U, \dots (7)$$

$$(Y) = (4.899802 \times 10^{-5} \quad 2.16993 \times 10^{-4} \quad 5.987319 \times 10^{-5}) * \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} \dots (8)$$

De la simulación se obtiene un par de columnas de datos de entrada y salida, colocando una computadora personal se calculo para la simulación, la señal de error  $e = r - y$  donde  $Y$  son datos muestreados a una frecuencia  $f=4\text{Hz}$ . La señal de entrada  $U = K_p * e$ , muestreada a  $f=4\text{Hz}$  obtenemos la Señal de Control.

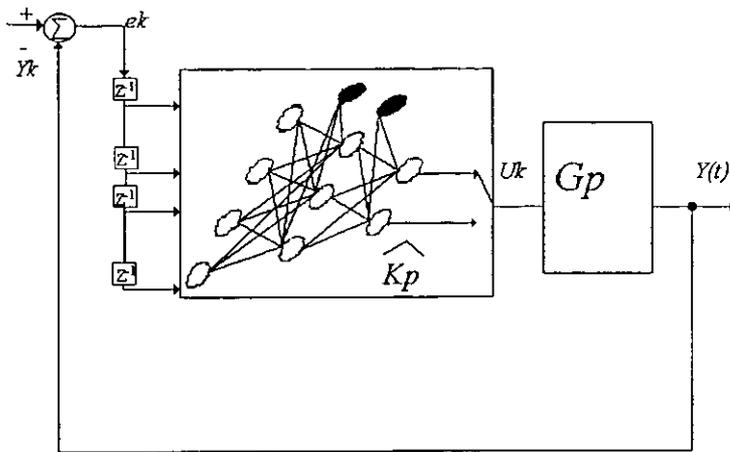
Del análisis de dichas señales se formaron las hipótesis de trabajo para la construcción de la red neuronal. Si una red con las características de retropropagación funciona bien al conectarse como controlador adaptable, se puede pensar que el uso de este método también se aplica en el control lineal (Ver figura 4 a).



En la figura: 4 Estructura de entrenamiento de la red neuronal a) podemos ver que la red neuronal tomara señales de entrenamiento a partir de la acción del controlador proporcional lineal, y en el dibujo

La posición del controlador lineal en la teoría de control dependerá de las bondades del sistema para obtener lectura de las variables de estudio que intervienen en ella, así llegamos a establecer lo siguiente:

Debido a que el sistema en estudio acepto cualquier tipo de controlador lineal seleccionamos la posición de controlador colocado antes de la planta en el lazo abierto de un sistema de control realimentado. Esperando obtener de la información del sistema de control lineal el suficiente material para definir el modelo de neurocontrolador de acuerdo a la complejidad que reporten dichos resultados (Ver figura 4 b).



b) La Red entrenada funcionando como neurocontrolador. (b)

En la figura: 4 b) se tendrá el neurocontrolador al hacer la sustitución del controlador proporcional por el neurocontrolador.

De las aplicaciones realizadas con filtro digitales conocemos los por menores del procesamiento en línea, de los cuales mencionaremos algunas propiedades básicas indispensables, es decir, es crítico el tiempo de procesamiento generado por la red neuronal que nunca deberá ser mayor al tiempo de muestreo por lo que en procesadores o microcontroladores es un factor crucial que se debe controlar en el número de líneas de programación o ciclos de cálculo. El otro elemento primordial a tomar en cuenta deberá ser el espacio de memoria de almacenamiento de datos cuando el proceso no se lleva a cabo en línea o la memoria disponible es escasa aun mas se debe evitar las interrupciones del disco duro por lectura o escritura de datos, que entorpezcan la buena digitalización de la señal de control.

Los datos generados por la simulación forman como ya dijimos un par de columnas (  $y$  ,  $u$  ) estos alimentan la entrada y salida de la red neuronal, se definió que solo se tomaría 4 datos de entrada correspondientes a las primeras 4 muestras. Siendo las muestra desplazadas una cada vez por el nuevo valor muestreado en un arreglo de 4 neuronas de entrada, siendo estos valores considerados como entradas pertenecientes a una secuencia en el tiempo a la velocidad de muestreo y con las características específicas de la señal de control.

A continuación se plantea una red neuronal con 4 neuronas de entrada cuya disposición tomará una muestra de la señal de entrada, si tomamos esta muestra y la colocamos en la primera posición de un vector de  $4 \times 1$  y recorremos dicha muestra a la siguiente posición cada vez que llega una nueva muestra tendremos al cabo de 4 tiempos de muestreo el vector de  $4 \times 1$  lleno, además cada vez que se desplaza una muestra decimos que ha ocurrido un retraso en el tiempo sobre la siguiente neurona de entrada.

Podemos notar que al introducir dicha forma de entradas en las cuatro neuronas de entrada, se incluye la variable tiempo al sistema y por la disposición reconocemos la

dinámica del proceso que deberá responder tanto a la inclinación de la pendiente mostrada por la señal de entrada, como al sentido de dicha pendiente, por ejemplo si la pendiente es positiva y nos encontramos por debajo del valor de referencia el sistema deberá responder con un aumento en el voltaje de control para alcanzar la estabilidad, durante la fase de levantamiento e inestabilidad del sistema, así como a variaciones significativamente menores que aparecen en la fase de estabilidad donde el sistema deberá reducir aun mas las diferencias con la referencia a partir de los indicios de valores casi iguales, y pendientes muy poco inclinadas.

Para conseguir que la red neuronal pueda discriminar correctamente entre los valores de las pendientes y las pequeñas variaciones del estado estable fue necesario hacer pruebas diversas con archivos de datos y con el ajuste de otros elementos de la red neuronal como son la tasa de aprendizaje y la ganancia, así como el número de épocas de entrenamiento estrechamente relacionado con el error de la red, de los cuales hablaremos posteriormente. La red neuronal mostrada esta diseñada como una red en adelante con 4 neuronas de entrada, 3 neuronas en la capa intermedia y dos neuronas de salida y un entrenamiento basado en las señales (y , u) (ver figura 5) de Salida del compresor y de control del compresor .

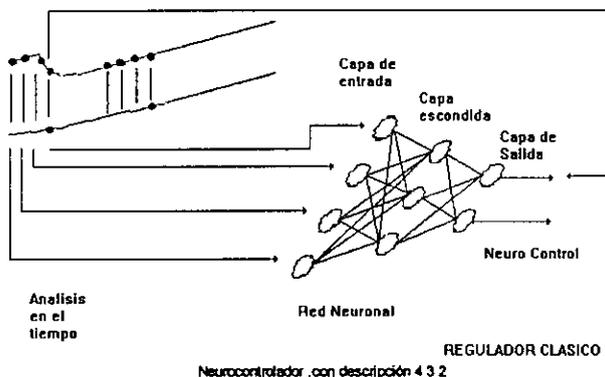


Figura: 5 Red Neuronal excitada por una señal con cuatro muestras de entrada y dos de salida.

Debido a que el análisis del sistema se realiza con el control proporcional no quiere decir que la respuesta obtenida condicione o perjudique la respuesta buscada, podemos notar que las características de respuesta dinámica del controlador proporcional con ganancia  $K_p=9$  son capaces de producir una respuesta que cubre el campo de medidas de 0 a 2 bar, aunque el comportamiento de la señal de salida durante el transitorio no sea el esperado.

Por lo tanto definimos de ello que el sistema si puede responder en todo el campo de medidas y responde a nuestras necesidades para establecer una respuesta a la salida del compresor de 0.25 bar/Volt cuando alimentamos al sistema con un valor de referencia constante entre 0 y 8V a la entrada del compresor, como sucede en el lazo abierto, y tratando de mejorar el comportamiento al tiempo del transitorio, al reducir su efecto o eliminarlo según sea el caso.

Con estas premisas habríamos de plantear las condiciones de respuesta del sistema optimas para el caso lineal, que son que el nivel de referencia a la entrada del sistema debe coincidir con el valor final de presión y la respuesta del sistema deberá tener el tiempo de levantamiento mínimo, sin que se presente sobrepaso. esto es una respuesta parecida al comportamiento lineal crítico o sobreamortiguado. Con el modelo discreto habremos de calcular la forma de respuesta en el tiempo para dichas condiciones.

### III. RESULTADOS

#### III.1 Enfoque de control lineal

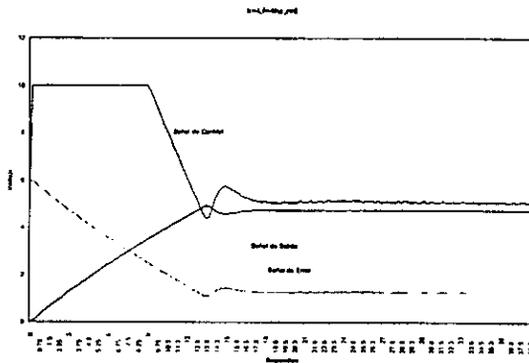


Figura:6 Comportamiento real la red neuronal. a) Muestra el comportamiento del compresor en lazo cerrado con  $k=4$ ,  $f=4\text{hz}$ ,  $r=\text{cte.}$ , y después de entrenada las señales de error, control y salida.

El control lineal hace su parte al servir como conceptos claros bajo la lente de una perspectiva nueva de análisis, la óptica lineal nos permite trabajar con controladores PI, PID y busca un desempeño optimo hasta conseguir la sintonización.

El control lineal hace su parte al servir como conceptos claros bajo la lente de una perspectiva nueva de análisis, la óptica lineal nos permite trabajar con controladores PI, PID y busca un desempeño optimo hasta conseguir la sintonización.

En los sistemas de control se espera conocer el comportamiento dinámico de sus variables a través de sensores para medir con exactitud cualquier cambio por pequeño que este sea en el sistema, con ello debemos emplear los actuadores apropiados para hacer del sistema de control un sistema de control estable, la respuesta debe mostrar un amortiguamiento razonable, la velocidad de respuesta debe ser rápida, y el sistema de control debe ser capaz de reducir los errores a cero, o a un valor pequeño tolerable.

El diseño de un controlador lineal como ya hemos visto se realiza con la función de transferencia. Se realiza el análisis y el diseño en  $S$  y en el dominio de la frecuencia, y su estudio está bien establecido al formularse una serie de reglas para la utilización del controlador aplicado al modelo matemático. Con el controlador y el modelo se puede simular el comportamiento que registra el sistema ante la acción lineal y a partir de la

Con estas premisas habríamos de plantear las condiciones de respuesta del sistema óptimas para el caso lineal, que son que el nivel de referencia a la entrada del sistema debe coincidir con el valor final de presión y la respuesta del sistema deberá tener el tiempo de levantamiento mínimo, sin que se presente sobrepaso. esto es una respuesta parecida al comportamiento lineal crítico o sobreamortiguado. Con el modelo discreto habremos de calcular la forma de respuesta en el tiempo para dichas condiciones.

### III. RESULTADOS

#### III.1 Enfoque de control lineal

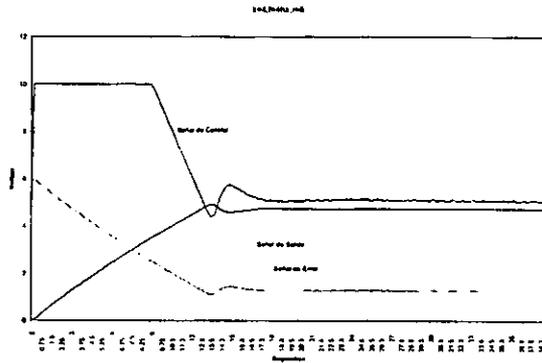


Figura:6 Comportamiento real la red neuronal. a) Muestra el comportamiento del compresor en lazo cerrado con  $k=4$ ,  $f=4\text{hz}$ ,  $r=\text{cte.}$ , y después de entrenada las señales de error, control y salida.

El control lineal hace su parte al servir como conceptos claros bajo la lente de una perspectiva nueva de análisis, la óptica lineal nos permite trabajar con controladores PI, PID y busca un desempeño óptimo hasta conseguir la sintonización.

El control lineal hace su parte al servir como conceptos claros bajo la lente de una perspectiva nueva de análisis, la óptica lineal nos permite trabajar con controladores PI, PID y busca un desempeño óptimo hasta conseguir la sintonización.

En los sistemas de control se espera conocer el comportamiento dinámico de sus variables a través de sensores para medir con exactitud cualquier cambio por pequeño que este sea en el sistema, con ello debemos emplear los actuadores apropiados para hacer del sistema de control un sistema de control estable, la respuesta debe mostrar un amortiguamiento razonable, la velocidad de respuesta debe ser rápida, y el sistema de control debe ser capaz de reducir los errores a cero, o a un valor pequeño tolerable.

El diseño de un controlador lineal como ya hemos visto se realiza con la función de transferencia. Se realiza el análisis y el diseño en S y en el dominio de la frecuencia, y su estudio está bien establecido al formularse una serie de reglas para la utilización del controlador aplicado al modelo matemático. Con el controlador y el modelo se puede simular el comportamiento que registra el sistema ante la acción lineal y a partir de la

respuesta idónea, este proceso es repetido hasta que se hayan satisfecho las especificaciones iniciales. En el caso lineal el uso del controlador PID será la base de aplicación para diseñar un controlador no lineal ya que no existe un método de aproximación para disminuir el error del sistema o más aun un método que plantee la forma de representar la acción de control es que se recurre a las técnicas ya establecidas.

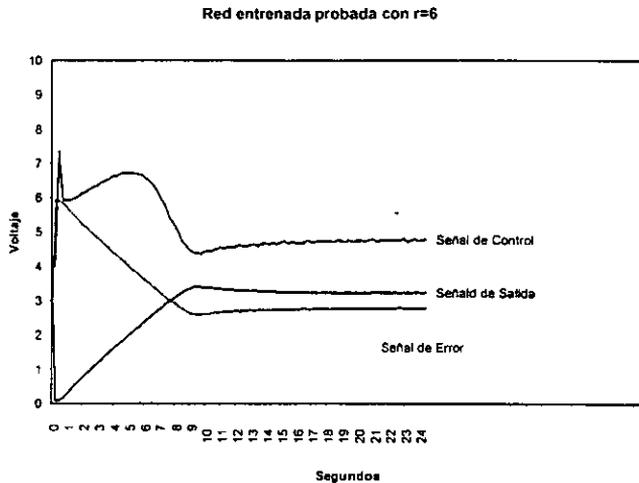


Figura:6 b) Comportamiento de la red neuronal entrenada con los patrones de comportamiento de la gráfica superior.

### III.2 MODELO DIGITAL

Hagamos nuevas consideraciones al modelado de señales, como sigue, a medida que probamos las condiciones de respuesta de la función de transferencia para conocer el funcionamiento del equipo, nos percatamos de la forma de respuesta gráfica y en el tiempo del sistema. Cuando dicho sistema es controlado proporcionalmente en el intervalo de estabilidad, es decir  $1 < K < 22$ . Los valores obtenidos a partir de la simulación limitan el estudio a una región estable es por ello que al emplear las respuestas de la señal de salida del sistema para crear una respuesta idónea estamos intrínsecamente delimitando la región de trabajo, al colocar la respuesta mejor controlada sobre una gráfica y sobreponerle la respuesta en el límite de estabilidad estamos sugiriendo que toda acción que caiga dentro del espacio delimitado por ambos comportamientos serán comportamientos deseables para su simulación. Las características de diseño de una red neuronal son mejor interpretadas desde una óptica gráfica y no tanto matemática. Por lo que podemos decir que la señal de entrada y salida de la red neuronal estarán representadas por dos gráficas o secuencias en el tiempo, que a su vez se dividen en un conglomerado de subsecuencias instantáneas denominadas ventanas que recorren la señal de entrada hasta completar toda la sucesión de puntos tomados en cada instante de muestreo a la entrada de la red, generándose una salida por valor de entrada en el arreglo denominado de ventana. (Ver figura 5)

---

Bajo esta perspectiva el comportamiento del sistema en la red neuronal puede ser trazado experimentalmente con una secuencia de datos o plantilla en el tiempo que manifieste las tendencias y particularidades gráficas del sistema.

Para lo cual debemos tomar las señales deseadas por separado (entrada, salida) analizando su forma y la acción que dicha forma produce sobre el sistema, y con ello poder generar una plantilla como sigue:

Para construir un controlador no lineal que mejore las características del controlador proporcional, generamos los pares de entrenamiento de la red neuronal con una señal de entrada simulada con el método de polos y ceros o bien discretizada de la señal de error con ayuda de una tarjeta de adquisición de datos (PCL-812), en conjunto con una señal de salida de la red neuronal o señal de control.

Dicha señal cuyos valores contienen las características de la plantilla con las mejoras deseadas de acuerdo al comportamiento lineal, es la señal que queremos entrene a la red neuronal y que deberá contener diversas respuestas lineales o no lineales tomando la mejor respuesta gráfica de cada simulación o proceso real para trazar una gráfica ideal que contenga a priori todas las mejoras perceptibles en cada respuesta lineal sin importar que este trazo sea linealmente inaceptable como una gráfica de control.

### III.2.1 LA PLANTILLA

La plantilla fue diseñada bajo las siguientes normativas, haciendo uso del modelo matemático obtenido previamente:

1. Se tomo un intervalo de ganancia de estabilidad entre  $1 < K < 22$ , para que coincidan con las referencias de entrada del sistema de control proporcional entre 0 y 8V.
  - Se selecciono un valor central de referencia  $r=5$  con el límite inferior de estabilidad  $k=1$ , para luego sobreponer la respuesta en el tiempo de la señal de salida en estas condiciones, con la señal de salida del sistema a una referencia  $r=5$  en el límite superior de estabilidad, o sea,  $k=22$  conocido como límite de oscilaciones sostenidas.
  - Por lo tanto podemos observar una señal oscilando con mucha ganancia y una señal pequeña con respuesta subamortiguada que delimita el espacio gráfico de respuesta estable del sistema para no forzar el mismo a condiciones indeseables.
  - De ambas gráficas se tomo en cuenta los límites de ganancia, como límites gráficos, además, se tomaron en cuenta la inclinación que produce el trazar una recta inclinada sobre las curvas de levantamiento como segundo límite de trabajo.
  - Otro elemento de análisis gráfico se plantea al intercambiar la señal de salida de la red neuronal correspondiente a la señal de control por una señal plantilla inventada.
2. Las características de la señal de error para la entrada de la red se disponen de la gráfica de la señal de salida al despejar de la fórmula  $e = r - y$ .

3. Dividamos el análisis de la respuesta del sistema en dos comportamientos destacables, el tiempo de levantamiento, y el tiempo de asentamiento:

a) El tiempo de levantamiento proponemos que sea una línea recta inclinada con una pendiente "m" que vaya incrementando su valor desde cero hasta el tiempo t<sub>lp</sub>. El tiempo t<sub>lp</sub> se habrá de calcular al tomar la cuarta parte del tiempo dispuesto entre las dos gráficas mencionadas del punto 1, si el tiempo máximo (T<sub>a(max)</sub>) corresponde al tiempo de asentamiento de la respuesta con ganancia k=1 y el tiempo mínimo (T<sub>p(min)</sub>) corresponde al tiempo pico de la primera oscilación respuesta con ganancia k=22.

De la gráfica sobrepuesta encontramos una relación o tiempo de levantamiento de la plantilla dado por:

$$T_{lp} = \frac{T_{a(max)} - T_{p(min)}}{4} + T_{p(min)} = 9.82s$$

Así que la pendiente "m" de la recta queda:

$$m = \frac{(X_2 - X_1)}{(Y_2 - Y_1)} = \frac{9.82 - 0}{5 - 0} = 0.5091$$

Para conseguir una estabilización de la señal de salida sin sobrepaso junto con la desaparición del error en el infinito, a partir de este tiempo t<sub>lp</sub>, se dibuja una recta horizontal a 5V. Por ultimo la señal gráfica de salida debe transformarse para representar la señal de error o señal de entrada de la red neuronal con e = r - y.

Donde el error tiende a cero e=0, cuando el valor de y es igual a r, r=y=5V.

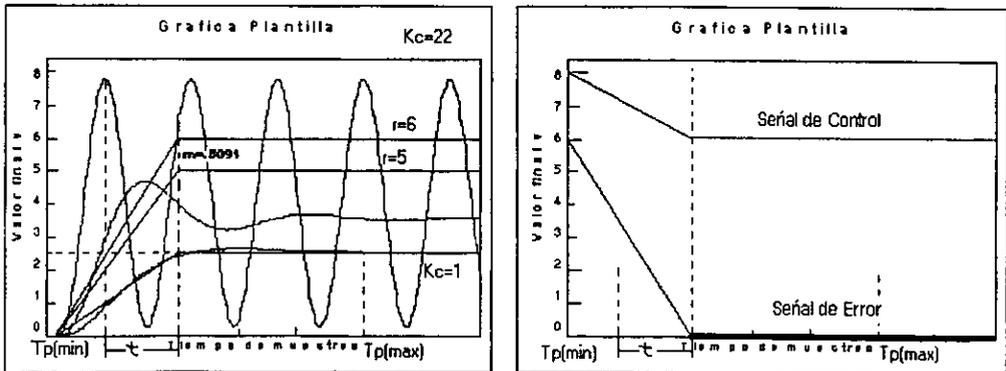


Figura 7 Representación de la plantilla

El modelo resultante (Ver Figura 7) constituye una abstracción del sistema real y en esta primera abstracción los resultados no fueron todo lo satisfactorio que se buscaban, sin embargo nos demostró claramente que el comportamiento inicial del sistema se puede estudiar por separado del comportamiento transitorio y el del comportamiento final.

Antes de obtener conclusiones apresuradas habríamos de caminar en la respuesta de otras interrogantes como el problema del llenado del tanque de aire del compresor que no se podía resolver linealmente, así que para resolver esta situación se planteo eliminar los modelos matemáticos lineales y aplicar las técnicas de trabajo directamente con el compresor, obteniendo archivos de las señales reales de control y las señales de error.

La válvula de control del compresor responde a la acción proporcional tanto en lazo abierto como en lazo cerrado y puede verse a partir del comportamiento dinámico del compresor que la respuesta a la acción de control manifiesta la respuesta a dicha acción donde por trivial que parezca describe un comportamiento único o característico del sistema de control empleado. La red neuronal elegida pretende realizar un mapeo de dicha dinámica característica para aprender la forma de llevar a cabo su tarea de control, esta tarea será especificada por el ingeniero o experto, quien como veremos es el encargado de interpretar las dinámicas así como de reconocer los factores que puedan dar una respuesta correcta a la salida de la red neuronal ante una entrada desconocida. Así, el objetivo del diseño de la respuesta de la red neuronal revisa por principio de cuentas el problema global y propone la topología de red y viene acompañado por la estructura de la red neuronal que en suma mapea los datos necesarios de comportamiento.

La red neuronal es entonces entrenada con patrones de respuesta estables para conseguir que la red responda a su vez con experiencia propia proporcionada por la base de conocimiento. Esta base de conocimiento es conocida como patrón de entrenamiento del sistema al cual se enfrenta la red neuronal por primera vez, es pertinente indicar que el patrón de entrenamiento debe contener la información necesaria para que la red pueda responder ante el sistema de manera independiente, o de otra forma, se haya producido el aprendizaje esperado. Debemos llamar entonces a la red neuronal "Controlador Neuronal". Después de que una red neuronal se construye, se espera que la respuesta sea razonablemente buena, ante una secuencia de datos de entrada. Los datos de entrada en conjunto generan un proceso interno en el controlador neuronal en el cual dicho proceso queremos que mejore en la acción de control con respecto a la acción lineal de donde provienen los datos de entrenamiento, aunque dicha acción se haya o no considerado.

A esta capacidad de la red de interpretar los datos de entrenamiento se le conoce con el nombre de generalización. De tal forma, un controlador neuronal debe generar una señal de control "U" que mejore las expectativas de aplicación comparativamente con un controlador lineal en las mismas circunstancias, que reduzca al máximo el sobrepaso y todo comportamiento transitorio indeseable. En el esquema de control clásico el controlador lineal, opera como un compresor controlado con realimentación, con la técnica del PID. La válvula actuara por efecto de un controlador proporcional P de tal forma que podamos describir el campo de acción de control en lazo abierto y cerrado, para determinar la función de transferencia.

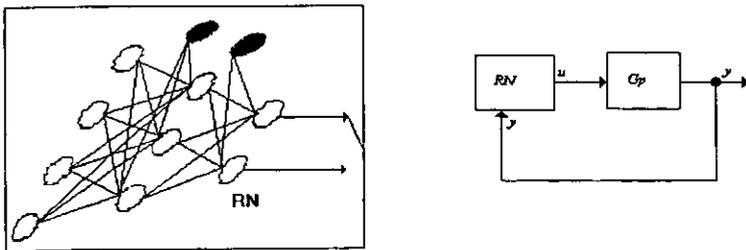


Figura:8 Estructura y Composición de la Red Neuronal

Como se ha podido ver, un procedimiento simple del diseño de un controlador neuronal para una planta neumática de 2 bars de presión se describe a continuación. Primero, seleccionamos los valores físicos adecuados para la función de entrada y salida de la red neuronal. La composición o estructura del controlador neuronal se escoge apropiadamente basados en las acciones de control esperadas (Ver figura 10).

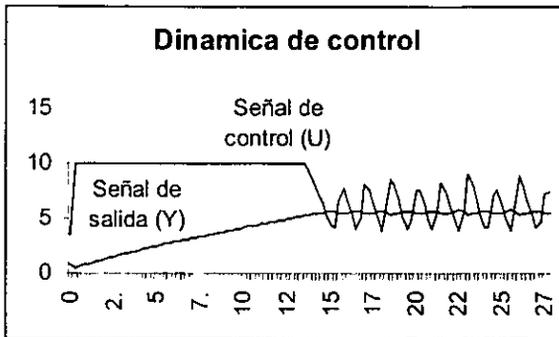


Figura:9 Secuencia en el tiempo de la dinámica de control.

Luego generamos el grupo de datos de entrenamiento que consiste de pares de datos correspondientes a la secuencia en el tiempo de la dinámica de control esperada (Ver figura 9) por el controlador neuronal para obtener el peso de conexión  $W$  objetivo y el valor de umbral  $\theta$ . Durante el proceso el error de la función de costo predefinida de la red neuronal puede ser reducida a un límite definido. Finalmente las pruebas al controlador neuronal se efectúan para evaluar su desempeño.

Hasta el momento nos hemos referido al diseño de los modelos para generar un grupo de datos patrón, con las características de la acción de control, para generar una red neuronal, pero que se puede decir de la propia red, al respecto podemos separar nuevamente el sistema a partir de la entrada, la salida y los pesos de conexión. La lógica común nos dice que para poder predecir el comportamiento de un sistema que responda adecuadamente ante la acción de otro sistema en estudio debemos conocer de este las particularidades necesarias para responder a cada una de ellas, así que, si conocemos la acción de control lineal correspondiente a un valor inicial de referencia  $r=2$  y decimos que el sistema en lazo cerrado controlado con una ganancia proporcional  $k=4$  cuando dicha acción se efectúa a la frecuencia  $f=4\text{hz}$ , se puede obtener una respuesta estable, y tomando la precaución de almacenar en un archivo de texto el comportamiento en el tiempo de las señales que entran y salen del bloque de control, esto implica que tenemos una particular respuesta del sistema a una particular referencia de entrada  $r=2$ .

Pues entonces, tomando del enunciado previo una línea de procedimiento debemos obtener los archivos de comportamiento en el tiempo de las señales de entrada representadas por las referencias de entrada  $r=\{2,3,4,5,6,7,8 \text{ y } 9\}$ . Una vez que se han obtenido los archivos individuales de cada situación podemos decir que al juntarlos en un único archivo de entrenamiento tenemos almacenadas todas las posibilidades necesarias nada más para entrenar la red neuronal. De las características de la red neuronal transformamos la colección de datos en un archivo nuevo que toma cuatro muestras de entrada del bloque de control por dos muestras de salida de tal forma que cada vez se lee un dato de entrada, este se coloca en la posición inicial del vector de 4 posiciones y de igual forma se coloca una

salida en el vector de 2 posiciones. a continuación y hasta finalizar con los datos se recorren las muestras en los vectores correspondientes.

El proceso de entrenamiento de la red neuronal se lleva a cabo cuando se toma una pareja de vectores de entrada y salida del archivo de entrenamiento y se muestra a la red neuronal, con lo cual el programa de entrenamiento se encarga de recorrer todo el archivo haciendo que la red modifique los pesos de conexión a medida que decrece el error del algoritmo de retropropagación.

El resultado del entrenamiento de la red neuronal, es un archivo de datos obtenido denominado archivo de pesos que contiene los pesos de conexión de dicha red, estos pesos representan “la memoria distribuida que al modificarse con el algoritmo de retropropagación genera los vectores del mapa del hiperespacio de la red neuronal”, que es donde se almacena el aprendizaje disperso de la red. En otras palabras la parte medular de la red. Este archivo debe ser examinado para conocer el tipo de respuesta que la red va a presentar cuando ésta se encuentra en la posición del bloque controlador.

Las pruebas a que nos referimos se llevan a cabo visualmente o por medio de un patrón de prueba que no contiene señal de salida y calcula el error entre la señal de salida obtenida y la del patrón de entrenamiento.

Podemos decir que debido al tipo de sistema de control, que es el realimentado, es difícil asegurar que la respuesta obtenida con el patrón de prueba sea en todos los casos aceptable, debido a que la realimentación usa en cada ciclo el nuevo comportamiento de la red y la prueba se realiza de una forma estática con patrones de prueba donde la red aun no ha interactuado con el sistema.

El proceso de generación de archivos no concluye aquí, ya que hay que probar la red neuronal recién entrenada en el lugar del bloque de control, dicha prueba consiste en hacer funcionar el sistema de lazo cerrado con el controlador neuronal, tomando las precauciones de almacenar los diferentes particularidades del sistema cuando hacemos variar el escalón inicial de entrada o valor de referencia de  $r=1$  a  $r=9$ , como lo hiciéramos para el control lineal. Las comparaciones son obligadas entre ambas respuestas del sistema y son el fundamento del análisis neuronal. Haciendo la cuenta del número de archivos que se necesitan para un análisis hemos generado 24 archivos para una sola red neuronal. (Ver figura 10 y 11).

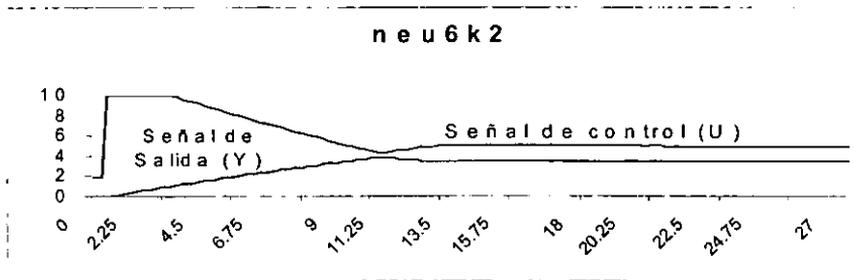


Figura: 10 Señales muestradas

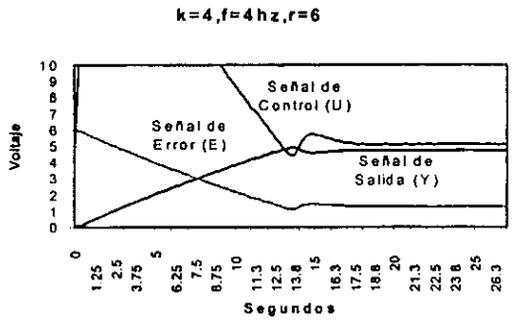


Figura: 11 Señales muestreadas reales.

Tomemos el ejemplo que ya comenzamos con  $k=4$  y  $f=4\text{hz}$ . Agregando los 8 archivos del grupo de datos de entrenamiento (Ver figura 10):

Tabla 1

referencia	segundos
r=2	0 a 12
r=3	12.25 a 54.5
r=4	54.75 a 82.75
r=5	83 a 111.75
r=6	112 a 136.75
r=7	137 a 161.75
r=8	162 a 193
r=9	193.25 a 231.5

Con ello construimos el archivo de entrenamiento F4RMULK4.TXT y formemos el archivo de transformación  $4*2$ , con este el archivo de entrada y salida como, F4RMULK4.io archivo que genera el archivo de red F4RMULK4.net, por último se toman de los pesos F4RMULK4.RED. luego hablaremos de los archivos de prueba.

De los resultados obtenidos en este estudio preliminar, tenemos un entrenamiento muy lento y debido a dos problemas que explicaremos a continuación los resultados fueron poco satisfactorios, retrasando los avances.

---

El primero de ellos se presento con los límites de respuesta de la válvula controladora que van de 0 a 8V, para lo cual el algoritmo de cálculo del controlador proporcional estaría ajustado erróneamente a los límites de la tarjeta PCL-812 es decir  $\pm 10V$ , así que la diferencia de 10 a 8 V esta diferencia de 2 volts ocasiono un desplazamiento en el tiempo de la respuesta del controlador neuronal ya que mientras se trataba de controlar 2 volts arriba del registro de la válvula del compresor esta solo tomaba el valor máximo de 8 volts durante el tiempo de voltaje superior a su límite y sumando los tiempos arriba y abajo de los 8 volts el compresor recibe entonces una señal de carga del tanque de aire mas prolongado del esperado.

El segundo problema que resultó mucho más complejo de analizar fue también de programación al tomar por equivocación tres de las cuatro neuronas de entrada, produciendo una respuesta que solo respondía en escasas ocasiones pero aún así lograba controlar. Podemos entonces decir que la tolerancia de la red neuronal a errores ocasionados por pérdidas de elementos procesadores puede afectar en cuanto al análisis de datos pero logra resolver con los elementos restantes y tolera cambios en el sistema aún cuando estos no hayan sido previstos por el diseñador del controlador neuronal. Estos acontecimientos fortuitos justifican el tiempo de análisis y diseño para la construcción de un controlador neuronal ya que una vez establecido, es capaz de soportar no solo cambios externos, sino internos que es un elemento con el que pocos controladores pueden competir, aún así cualquier degradación del sistema puede ser tomada como peculiaridad y si además el algoritmo utilizado para esta red se auto regula en línea el problema se resuelve automáticamente sin necesidad de cambiar de equipo o hacer reparaciones y al mismo tiempo sin perder el control del sistema.

Por último hagamos mas complejo el estudio al incrementar las incógnitas para poder sintetizar posteriormente en una dirección certera.

Los archivos tomados a una frecuencia  $f=4\text{hz}$ , que nos permite ver oscilaciones indeseables que ocultan el comportamiento ideal del compresor, se presentaban únicamente a bajas frecuencias, como resultado del lógico análisis se aumenta la frecuencia  $f=20\text{hz}$  y que se presenta una restricción el tamaño de los archivos generados por la discretización se dispara. Existe entonces un fuerte compromiso entre el grado de respuesta de control que se quiere y la frecuencia de muestreo, siendo más problemático en el sistema de lazo cerrado, ya que el mismo depende de la salida de control a dicha frecuencia, que regresa por el lazo de realimentación.

Para corregir este problema se puede reducir la frecuencia a costa del conocimiento de la planta neumática, ya que se pierden características de estudio debido a las zonas de oscilación.

Tomemos otras decisiones para reducir el tiempo de entrenamiento, para éste momento habremos corregido el error de la diferencia de 2 volts.

Nuestro estudio por fuerza requiere de mucha memoria y se seleccionaron algunos archivos del universo posible para no sobrepasar la capacidad de entrenamiento y la capacidad de análisis objetivo, con ejemplos  $k=2,4,5$  y referencias entre  $r=1$  y  $9$  (Ver figura 12).

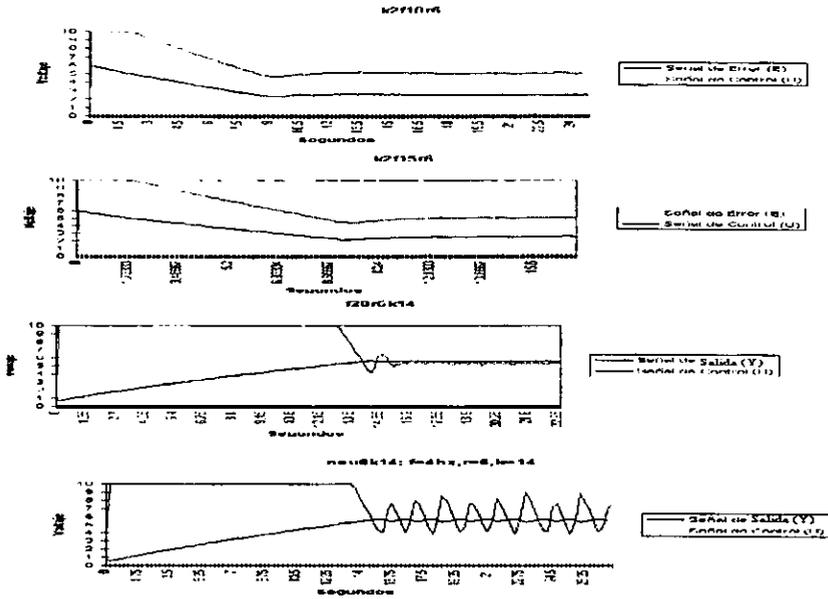


Figura:12 a  $f=10\text{hz}$  con menos información que la adquirida a mayor frecuencia,

La siguiente meta a vencer consistía en manejar las variables de la red para obtener un mejor entrenamiento, para conocer la forma en que generalizan las redes neuronales, así como las variables de aprendizaje que nos permitan llegar a una red neuronal que mejore el comportamiento de un controlador lineal en el modelo de lazo cerrado.

El ingeniero debe utilizar su propio aprendizaje de los comportamientos por separado de los sistemas que maneja y debe ser la guía que se encarga de elegir los patrones de aprendizaje que contenga la información necesaria de la compresora, con una valoración de la capacidad de almacenamiento de datos en el hiperespacio compuesto por el mapa dinámico de los pesos de la red neuronal, de acuerdo, al número de estos y el número de procesadores involucrados (tamaño de la red).

Las redes neuronales entrenadas con estos patrones de datos tan numeroso generaron un comportamiento del error contrario al esperado ya que el cambio en el error en la ley de aprendizaje es muy grande por involucrar un calculo del error medio cuadrático y por consiguiente, el error no disminuía adecuadamente para producir el aprendizaje buscado, para corregir esta deficiencia se modificaron parámetros tales como la tasa de aprendizaje, se penso modificar la ley de aprendizaje o cambiar el calculo del error máximo absoluto que no varía tan drásticamente, e incluso se penso en modificar las características de la topología alterando la ganancia de la función de activación o incrementar ya fuera el

---

número de neuronas en la capa de entrada o incrementar una capa escondida para mejorar los resultados.

Del grupo de acciones posibles se tomaron primero las menos drásticas, ya que para corregir el comportamiento del error que comenzaba en un valor pequeño y después de disminuir un poco permanecía constante de tal forma que se quedaba atorado en un mínimo local, se vario la tasa de aprendizaje, y el número de épocas de entrenamiento con el mismo resultado.

Las pocas redes que entrenaban generalizaron con un desplazamiento de la respuesta, que parecía coincidir con el comportamiento de la señal de entrada y que sería el primer indicio de la forma que deberían tener los patrones que queremos para el entrenamiento, ya que la red generaliza sobre las diferencias de señales y considera menos relevante los estados invariantes.

El análisis resultante, nos condujo a reducir el número de patrones de entrenamiento ya no al rango completo de datos, pero si de tres o cuatro grupos compuestos por la serie de pares de datos que componen la respuesta en el tiempo del compresor durante la acción del controlador, como resultado los entrenamientos comenzaron a mejorar, y entonces, ya no sería necesario cambiar la estructura de la red u otros parámetros.

Pero la solución del modelo exigía otro tipo de análisis para ser efectivo, así pues, acotamos el estudio a límites menos ambiciosos y mucho más específicos para solucionar cada peculiaridad del trabajo.

El siguiente paso en el entrenamiento es hacer archivos con tiempo de estabilización proporcionalmente largo al tiempo de señal estable, tomando una medida estándar, para tiempo, fijado arbitrariamente; así pues, se eligió un tiempo de levantamiento igual al tiempo en estado estable.

Otro cambio drástico que condujo a la culminación de todos los esfuerzos hacia un camino correcto, se dio al disminuir el número de patrones a (200 muestras), o lo que es lo mismo una dinámica con  $k=cte.$  y  $r=variable$ , pudiendo elegir una  $k=4$  porque la respuesta del compresor cubría el intervalo de presión de 0 a 2 bar, a un frecuencia de  $f = 10 \text{ hz}$  lo que equivale a patrones de entrenamiento individuales desde 117 datos hasta 441 correspondientes a referencias desde  $r=2$  hasta  $r=9$ .

Con estos resultados podemos asegurar un entrenamiento de la red neuronal confiable, y enfocarnos a las mejores características del grupo de datos de entrenamiento, así como nuevos parámetros.

Probamos la respuesta de la red con excelentes resultados, concentrándonos en el valor de referencia cualquiera ya que fijamos la frecuencia a  $f=10\text{hz}$ , y la constante de proporcionalidad  $k=4$ .

Aún a pesar de lograr este avance en este punto se formo otro archivo masivo con 8 respuestas dinámicas para entrenar a la red neuronal con respuesta bastante buena, lo que nos conduce finalmente a decir que con menos patrones la red tiene mas libertad de decidir como se entrena y que es menos posible que quede atrapada en un mínimo local.

En este punto se notaron algunos corrimientos o desplazamiento en las respuestas dinámicas de la red, debido a varios factores, un desplazamiento no controlado de un desajuste de las características del equipo accesorio de conversión de señal, tanto a la entrada como a la salida y que se tendría que verificar periódicamente, junto con otros desajustes inherentes del funcionamiento del compresor como es el aumento de la temperatura en los transistores cercanos al motor, y que reta la imaginación del instrumentista y del ingeniero para medir factores como un gradiente de temperatura con sensores distribuidos sobre todo el equipo, y el ambiente.

Al corregir el punto de operación de los elementos de conversión de las señales obtuvimos nuevas redes, que operaban cada vez mejor:

A partir del momento en que se consigue que las redes neuronales sean confiables se explicara el modo con el que hemos estado probando las redes y que nos permite saber que tan bien entrenadas se encuentran y por consiguiente separar aquellas que han generalizado correctamente de las que no lo han conseguido.

La forma adecuada que la bibliografía plantea es la de probar las redes aplicando patrones nunca antes vistos por la red que correspondan con el modelo estudiado(Ver figura 13).

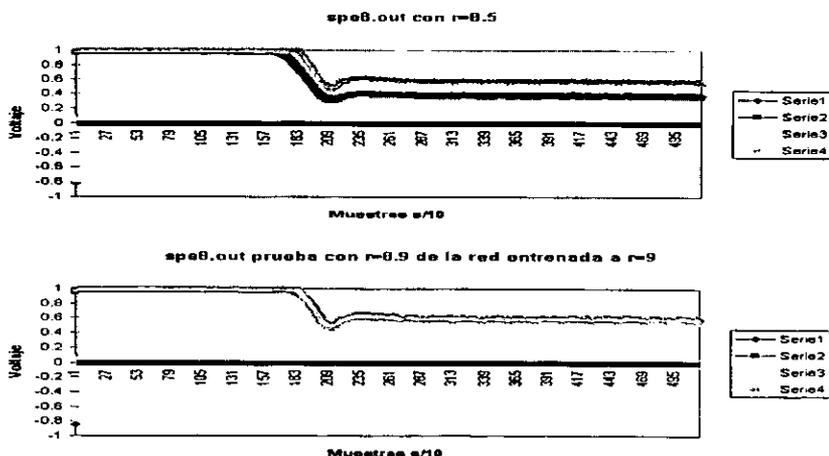


Figura:13 El resultado de las pruebas:a la referencia de entrada  $r=9$  que ha sido probada con una referencia  $r=8.5v$ .

De tal forma, obtenemos para cada red neuronal dos grupos de datos, uno consiste en el grupo de pares de entrenamiento obtenidos a partir de la discretización de las señales de (error, control) del sistema de lazo cerrado con un controlador proporcional  $K_c$  constante y una referencia  $r$  variable en el grupo de los enteros.

Dentro del segundo grupo de datos, conocido como grupo de patrones de prueba aumentamos a la referencia 0.5 v para diferenciar claramente ambos grupos (Ver figura 13).

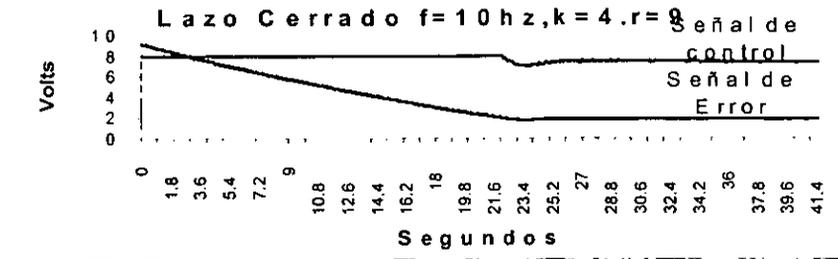


Figura:14 Una sola dinámica

Como ya dijimos el uso de una sola dinámica (Ver figura 14) estandarizo mucho el proceso de entrenamiento y notamos un comportamiento del error durante el entrenamiento que la bibliografía denomina sobreentrenamiento que se presenta después de un número de épocas de entrenamiento muy largo, por lo que tomamos una medida mediana para fijar el punto en el que no se presentara este sobreentrenamiento y que habremos de fijar en 5000 épocas.

El comportamiento de la red neuronal visto hacia adentro de la misma, toma características similares a otros procesos matemáticos y puede ser un buen elemento de comparación debido a que al tomar muestras de la señal con un retraso en el tiempo  $Z^{-1}$  y el cual pasa a través de 4 retardos. La forma de representar el comportamiento del sistema, y por lo tanto las particularidades de dicho sistema pueden ser analizadas a partir del comportamiento dinámico de un solo trazo que contenga las especificaciones de ganancia, referencia, frecuencia, y todo lo que registre dicho trazo único y representativo, la interpretación al respecto sugiere que las características de todo el sistema están contenidas en un solo archivo y que las técnicas de normalización para representar estas características pueden ser validas, es decir, que la respuesta del sistema a una referencia escalón positivo unitario puede representar en todos sus detalles al sistema en estudio, y que la red va a tomar un aprendizaje estadístico del comportamiento de un trazo único (Ver figura 14).

Estas ideas se respaldan en los resultados obtenidos durante esta parte de la investigación, así pues al concentrarnos en un solo trazo encontramos que es posible obtener de ello un comportamiento que relaciona la dinámica de control, con la respuesta del sistema, y que para ello se pueden observar las condiciones de entrenamiento con el objetivo de conocer de ante mano el tipo de respuesta que se va a obtener cuando el controlador neuronal entrenado esté actuando en la posición del bloque de control. Si como veremos conseguimos saber de antemano el tipo de control neuronal que queremos podemos establecer que ya hemos separado las características representativas del sistema, para incluirla en un diseño de control neuronal y que de acuerdo a dicha selección de características será el tipo de respuesta que obtendremos, lo cual nos permitiría generar una base de patrones comunes para cada tipo de respuesta esperada y de la cual seleccionar la mas indicada, como seleccionar la formula para resolver una integral o derivada en el tiempo.

Debido al amplio proceso de experimentación encontramos el valor máximo de llenado del compresor de aire. Este satisfacía con las ecuaciones que evalúan las señales de error y control al contar con pendientes de la curva de levantamiento inferiores a aquellas que producían un sobrepaso al igual que se suaviza el cambio de pendientes al hacer una curva continua subarmortiguada hasta la estabilización.

La experiencia adquirida al emplear el compresor con el control lineal nos a permitido reconocer el comportamiento en el tiempo de levantamiento que es inevitablemente constante e inalterable, es decir, siempre se presenta con la misma velocidad máxima y no nos interesa reducirlo ni alterarlo.

A partir de este conocimiento nos preocupamos por el resto del comportamiento dinámico de control haciendo una división del trazo del sistema en 3 partes, el primero es el tiempo de levantamiento el cual es controlado plenamente si se aplica un escalón de 8V durante el período seleccionado para alcanzar el nivel de presión adecuado, de acuerdo con una gráfica de crecimiento, el número de muestras contra el voltaje medido en el transductor de presión y que puede obtenerse de la tabla, del ejemplo.

La segunda parte de la señal de control corresponde al establecimiento del sistema como puede apreciarse en la tabla 2 la señal de control cambia abruptamente de un valor constante 8V al siguiente valor indicado en un tiempo.

Pero todo lo que hagamos a la señal de control lo tenemos que reflejar también a la señal de error para lo cual hacemos uso de la misma tabla diciendo que la señal de salida que queremos obtener deberá crecer linealmente comportándose como una pendiente desde el tiempo 0 hasta el tiempo de levantamiento en la segunda columna de la tabla 2, como ya dijimos esta parte corresponde al tiempo de levantamiento y la segunda parte o tiempo de estabilización quedará representada por una recta horizontal sin sobrepasos, que durará el resto del tiempo a partir del tiempo de levantamiento.

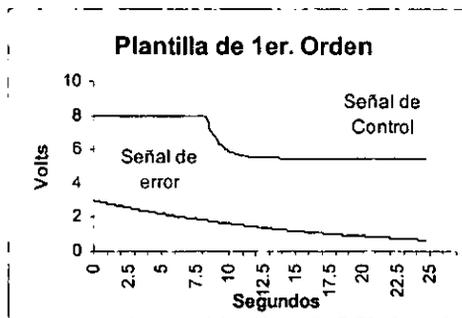


Figura:15 Plantilla de entrenamiento para condiciones no existentes en la realidad, con una entrada inventada y una salida inventada.

Para el caso de la referencia de 1 volt:

**Entrada:** Con un archivo de 24.6 segundos se traza una señal de salida (y) que toma 2.8 segundos para dibujar una línea recta inclinada desde 8 volts hasta 1 volt que a partir del segundo 2.9 permanece constante a 1volt, posterior mente se calcula algebraicamente como señal de error  $e = r - y$  y donde  $r = 1$  volt.

**Salida:** Con un archivo de 24.6 segundos se traza una señal de control (u) que toma 2.8 segundos para dibujar una línea horizontal a 8 volts, que a partir del segundo 2.9 permanece constante a 5 volts (Ver figura 7).

Para el caso de las referencias subsecuentes haremos una tabla (Tabla 2):

Voltaje de referencia	Segunods en que se presenta el escalón	Escalón invertido
1V	2.8	8 a 5
2V	5.5	8 a 5.5
3V	8.2	8 a 5.5
4V	11.4	8 a 6
5V	14.9	8 a 7
6V	18.8	8 a 7.3
7V	23.6	8 a 7.8

Los entrenamientos con plantilla se tomaron en combinación con las señales reales, es decir podemos tener(Ver figura 15):

Entrada	Salida
real	real
real	plantilla
plantilla	real
plantilla	plantilla

Los resultados no fueron del todo satisfactorios ya que se esperaban sobrepasos menores que los presentados con el controlador proporcional, pero al no ser así, se penso en suavizar los cambios abrupto que habíamos escogido de la señal recortada.

Para redondear este proceso hemos mencionado 3 partes, de las cuales la tercera no existe y es precisamente la que controla el transitorio de la señal de salida del compresor:

Diversas formas se introdujeron como entrada y salida, hasta concretar una simplificación exitosa de las señales del compresor resultando la eliminación de los sobrepasos en el sistema debidos a los cambios abruptos de escalones invertidos y rampas que fueron la base del éxito. La señal de salida esta compuesta por tres formas básicas, la primera representada por una recta horizontal que representa el tiempo de crecimiento de la presión por el llenado del recipiente de aire, la segunda forma que corresponde a una curva exponencial invertida que suaviza la respuesta del controlador para alcanzar la estabilidad completa del

sistema eliminando todo sobrepaso posible, y la tercera forma corresponde al tiempo estable y que es representado como una recta horizontal sin cambio.

Toda clase de combinaciones entrada-salida benefició el estudio final del compresor, ya que las señales novedosas aplicadas de primer orden se incluyo como señal de error para suavizar el cambio abrupto del modelo previo con una constante de tiempo T que dependía de la señal de salida, en cuanto a determinar la duración del tiempo de levantamiento mas el tiempo transitorio.

Ahora bien el momento de cambio en la señal de salida será la relación que permite obtener el valor de T, si consideramos el número de muestras que hay entre 0 y el cambio en las primeras dos formas de salida la de levantamiento y el transitorio, dicho valor (segundos), lo dividimos entre 5, para encontrar el valor en el que la exponencial cumple con el 99.3% del valor final de entrada:

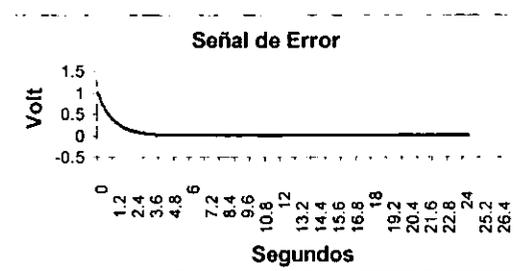


Figura 16. Representación de la señal de error.

$$X=1- e^{-t} \dots(11)$$

Esta ecuación representa la señal de error que es una exponencial decreciente con inicio en uno y termino en cero donde el valor de inicio corresponde al de la referencia normalizada y el valor de cero es un valor del error final.

Proseguimos entonces con las estructuras planteadas hasta el momento, ya dijimos que el tiempo de levantamiento siempre es igual y también dijimos que podemos controlar el transitorio, entonces, ¿Como es el transitorio en comparación con el del controlador neuronal?

El modelo anterior produjo un transitorio mayor ya que de echo no lo tomaba en cuenta, pero este nuevo modelo a logrado mejorar la respuesta del transitorio en todas las referencias y ya que hemos logrado controlar la respuesta transitoria.

Sin duda el siguiente paso es más sorprendente, el planteamiento del sistema no ha podido resolver un problema delimitado por el tipo de respuesta del controlador lineal proporcional con el que hemos estado trabajando, así que habremos de implementar el controlador PID, con ello buscamos conocer un controlador que mejore la respuesta obtenida por la red neuronal hasta el momento.

---

### III.3 DISEÑO E IMPLEMENTACIÓN DEL CONTROLADOR PID.

Esta sección describe el diseño e implementación del controlador PID. El PID es una técnica comúnmente utilizada en control clásico. En el diseño de controladores, a veces sucede que solamente minimizar el término proporcional del error no es suficiente. Incluyendo el término integral del error se reduce el error en estado estable a cero porque representa el error acumulado. Posteriormente se mejora la estabilidad y la dinámica de la planta, al introducir el término diferencial del error. Este término representa la tasa de error. Un controlador PID que incluye los tres términos puede dar excelentes resultados. Esta técnica también se utiliza en forma discreta en sistemas de control digital.

Se emplean dos aproximaciones diferentes para convertir el PID a su forma discreta, la rectangular y la aproximación trapezoidal. Para la aproximación rectangular, el diseño se hace en el dominio analógico y se convierte al dominio de Z. Para la aproximación trapezoidal, el diseño se hace directamente en el dominio de Z, utilizando la técnica de posición de los polos. El algoritmo analógico está dado por:

$$U(t) = K_p e(t) + K_i \int dt + K_d \frac{\partial e}{\partial t} \dots (12)$$

Donde

**K<sub>p</sub>; K<sub>i</sub> ; K<sub>d</sub>** = son constantes del PID (ganancias del PID)

**u(t)** = salida del controlador (señal de control)

**e(t)** = señal de error

Transformando mediante integración rectangular la forma discreta y calculada la respectiva ecuación en diferencias queda

$$U(n) = U(n-2) + K_1 e(n) + K_2 e(n-1) + K_3 e(n-2) \dots (13)$$

donde

$$K_1 = K_p + K_p/T + K_i T$$

$$K_2 = K_i T - 2K_d/T$$

$$K_3 = K_d/T - K_p$$

U(n) = señal de control en el intervalo de tiempo n.

U(n-2) = es la segunda diferencia hacia atrás

e(n) = señal de error al tiempo n.

e(n-1) = señal de error al tiempo n-1.

T = intervalo de muestreo.

Usando la transformación bilineal o trapezoidal:

$$U(n) = U(n-2) + K_1 e(n) + K_2 e(n-1) + K_3 e(n-2) \dots (14)$$

donde

$$K_1 = K_p + 2K_p/T + K_i T/2$$

$$K_2 = K_i T - 4K_d/T$$

$$K_3 = 2K_d/T - K_p + K_i T/2$$

U(n) = es la muestra enésima de la salida del controlador.

U(n-2) = es la segunda diferencia.

Las características para el controlador PID trapezoidal quedaron como sigue:

$$K=4, R=4, K_i=0.007, K_d=80, N=10, F=10$$

Con lo cuál se ha analizado un factor que hasta el momento no podemos controlar con el controlador neuronal y se refiere al nivel final de presión alcanzado a partir de la referencia indicada y además, el controlador no lineal debe ser capaz de responder a cada una de las referencias de entrada, produciendo el mismo valor final, con tiempo de levantamiento conocido y prácticamente sin sobrepaso

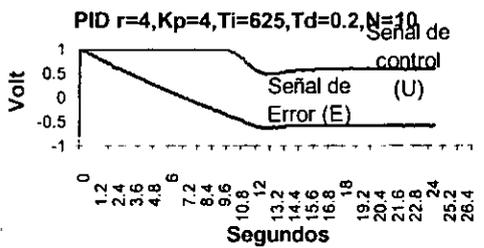


Figura:17 Señales de respuesta lineal con sobrepaso y un tiempo de asentamiento  $T_p=12.7s$

Al momento de hacer los entrenamientos con las señales reales del PID notamos un aumento de 2V, en el valor final para la mayoría de los casos, por lo que creemos que el modelo de entrenamiento debe ser diferente de la señal real, ya que el análisis no nos ha permitido localizar en donde se presenta el desplazamiento indeseable y que afecta el entrenamiento o la respuesta adecuada.

Definamos el tipo de comportamiento de la señal de error y control para conseguir un comportamiento anticipado, con base en los cambios en la plantilla anterior:

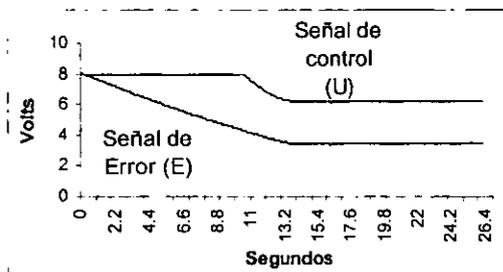


Figura 18, Respuesta real del Compresor al neurocontrolador. Prueba con la referencia  $r=8$  a la red neuronal entrenada.

El uso del método digital que calcula el algoritmo PID encuentra rápidamente los resultados con el Neurocontrolador, sin llegar a mejorar las respuestas de control no-lineal. Las características para el controlador PID trapezoidal formado por la ecuación anterior nos muestra un resultado que trataremos de obtener con las redes neuronales y que consiste en un Valor final de  $V_f=4.597v$  con un Sobrepaso de  $M_p=4.6269$  cuando el tiempo pico es  $T_p=12.6s$  si el sistema es alimentado con una señal de referencia  $r=4v$ .

### PID TRAPEZOIDAL



Figura 19. Respuesta del compresor al controlador PID trapezoidal.

Al entrenar las redes neuronales hemos obtenido un Neurocontrolador que mejora las características del controlador lineal al tener un Valor final de  $V_f = 4.497v$  con un valor  $V = 4.3212$  cuando el tiempo alcanza  $t = 12.7s$  sin sobrepaso a una referencia  $r = 8v$ , lo que significa que el resultado no está a la mitad de la escala.

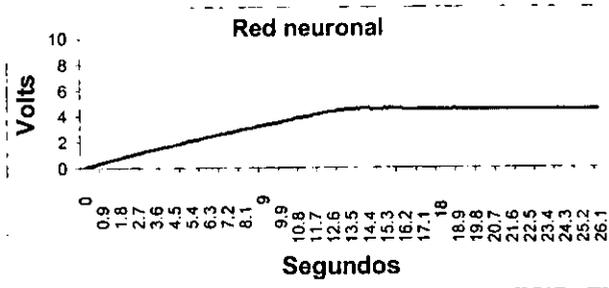


Figura 20. Respuesta del compresor a la Red neuronal.

Teniendo que mejorar los criterios de búsqueda de respuesta y entrenamiento para una Red neuronal sin sobrepaso a la mitad de la escala, de referencia  $r = 8v$  y la mitad de la escala de presión  $P_f = 1$  bar que equivale a  $V_f = 4v$ .

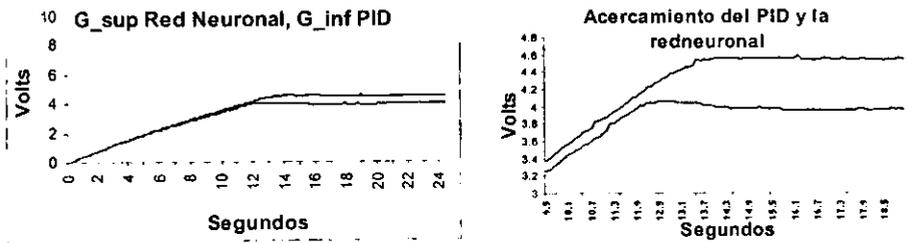


Figura 21. Comparación de las respuestas de salida de la planta ante la acción de control lineal y no-lineal.

### III.4 Plantilla Mejorada

Nos preguntamos si ¿La distancia entre las señales de error y control interviene en la determinación de la referencia? O ¿Determinar si la constante de llenado del compresor se relaciona con la referencia?

Nos referimos gráficamente a que cambios requieren las dos señales para producir un tipo de respuesta, si queremos que este par de señales entrenen al neurocontrolador que al momento de generalizar produzca la corrección del error de posición, de modo que la red neuronal se relacione con la señal de referencia como punto de comparación para cada respuesta dinámica obtenida de la aplicación del neurocontrolador asociado a la distancia entre la señal de entrada y salida o, si la constante de llenado por si sola determina el tiempo de levantamiento que permite que aumente la presión cuando llena de aire el cilindro del compresor y esto determina la referencia de entrada necesaria para que el neurocontrolador responda a una referencia fijada por esta variable a los cambios de presión máxima para alcanzar el valor de presión correspondiente al esperado por una referencia indicada entre 1 volt y 9 volts. De las gráficas podemos observar que la señal de error comienza en el valor de referencia en el tiempo cero.

Mas adelante veremos que si existe relación entre la referencia y el tiempo de llenado del cilindro de aire del compresor, pero no con la distancia entre señales.

Para poder responder estas incógnitas y otras más de los trazos de las señales de error y control modificamos primero la señal de control, decimos que:

La señal de control comienza con un escalón de 8 volts del tiempo 0 al tiempo  $t=0.8$  s, posteriormente se representa por la ecuación  $S_c = 5 + 3e^{-t}$  donde el valor de inicio de la exponencial invertida son 8 volts y el valor final son 5 volts (Ver figura 23).

$$S_c = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5 + 3e^{-t} & \text{si } t > 0.8s \end{cases}$$

Por su parte la señal de error formara una tabla de nueve cambios en la ecuación original (Ver figura 20).

Tabla 4

$$\begin{array}{lll} S e_1 = e^{-t} & S e_2 = -1 + 2e^{-t} & S e_3 = -2 + 3e^{-t} \\ S e_4 = e^{-(t/5.6)} & S e_5 = -1 + 2e^{-(t/5.6)} & S e_6 = -2 + 3e^{-(t/5.6)} \\ S e_7 = e^{-(t/2)} & S e_8 = -1 + 2e^{-(t/2)} & S e_9 = -2 + 3e^{-(t/2)} \end{array}$$

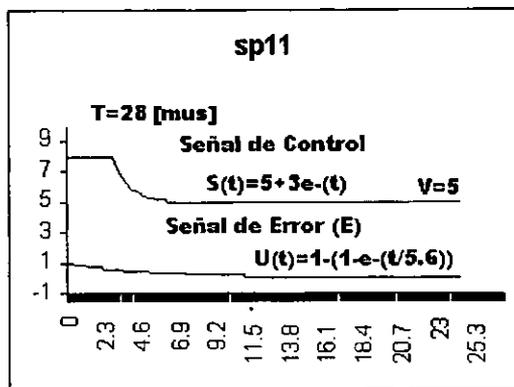
Las columnas nos muestran cambios en la distancia entre la señal de error y control mientras que los renglones nos muestran cambios en la pendiente de la exponencial.

Estos cambios que afectan la señal de error nos sirven para alterar la pendiente de la exponencial de acuerdo con el tiempo que requerimos mantener el periodo de estabilidad de la señal de error, además variamos el escalón para obtener el comportamiento desde 1 a 0 volts, de 1 a -1 volts, de 1 a -2 volts, respectivamente para entrenar 9 redes neuronales cuyos comportamiento debemos probar.

A continuación se muestran los resultados obtenidos a partir de los comportamientos de las redes neuronales entrenadas, cuando son comparadas por un simulador de condiciones reales de respuesta de la red entrenada, este simulador nos permite saber que tan cercanamente ha aprendido las redes neuronales de acuerdo a la respuesta que se obtiene al colocar un patrón que nunca antes hayan visto durante su entrenamiento, estos patrones para cada una de las 9 redes entrenadas son las señales reales las que se va a enfrentar el neurocontrolador una vez que la red neuronal es seleccionado, las respuestas deben estar muy cerca de las respuestas de entrenamiento y responder conforme a la señal que reciben como entrada, es pertinente decir que esta vez no se muestra la salida a la red neuronal, ya que se pretende que la red actúe de acuerdo a su entrenamiento.

De las señales que veremos a continuación podemos notar que los comportamiento de respuesta concuerdan con las características de las señales de entrenamiento y que el error es pequeño, sin embargo no nos permite saber con certeza que efectos producirán estos resultados en el sistema real.

Las gráficas corresponden a los entrenamientos de la plantilla mostrada como señal de error y control (ver figura 22) y las ecuaciones anteriores, nombrando cada una de ellas con una letra de la "a" hasta la "i",



$$S(t)=r2+(8-r2)e^{-(t)}$$

$$R2=5$$

$$S(t)=5+3e^{-(t)}$$

$$T=28/5=5.6$$

$$C(t)=1-e^{-(t/5.6)}$$

$$U(t)=1-C(t)$$

Figura:22 Señales Inventadas

Tabla 5

Red Número	Tipo	Señales error
1	a	Se1
2	b	Se2
3	c	Se3
4	d	Se4
5	e	Se5
6	f	Se6
7	g	Se7
8	h	Se8
9	i	Se9

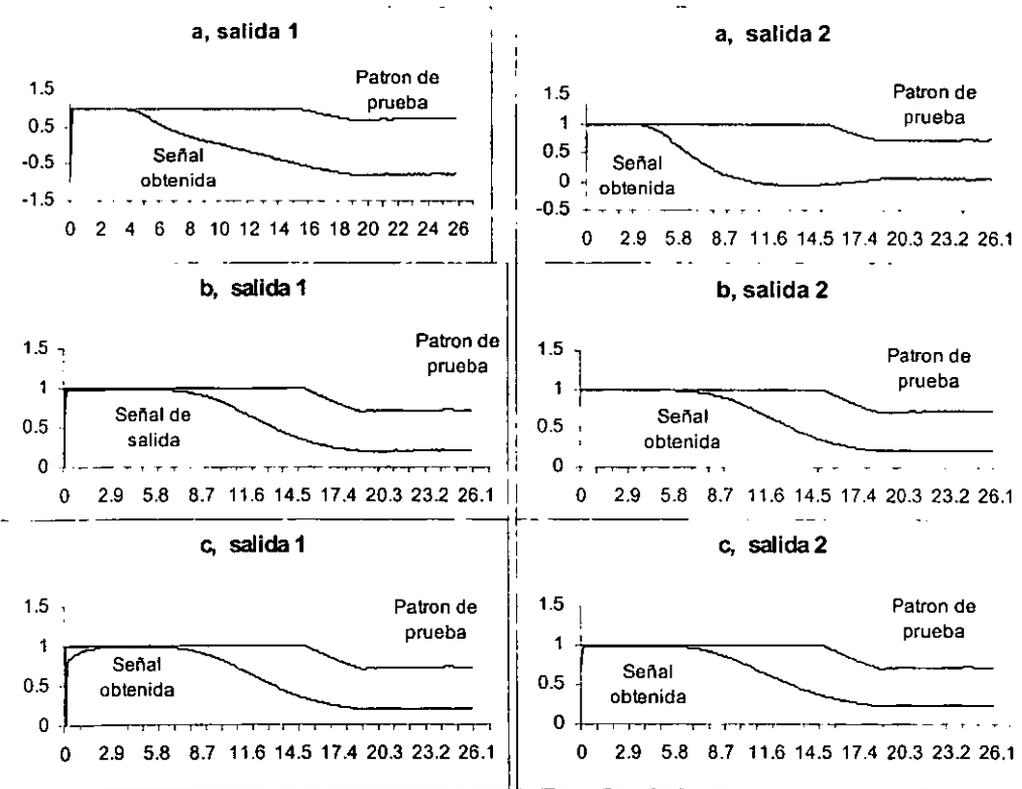


Figura: 23 Pruebas fuera de Línea de las seis redes entrenadas con cambios progresivos de acuerdo a las pendientes y las alturas entre curvas.

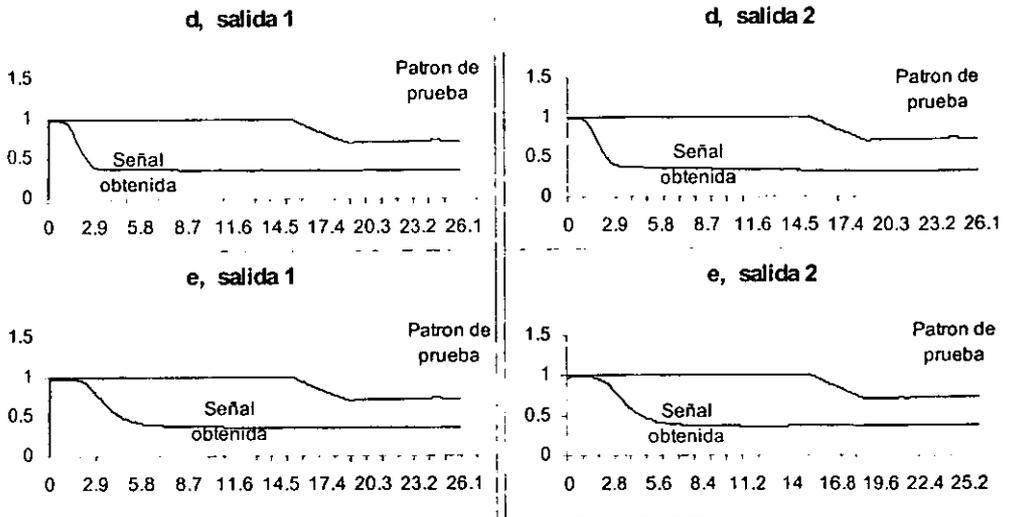


Figura: 24 Pruebas fuera de Línea de las seis redes entrenadas con cambios progresivos de acuerdo a las pendientes y las alturas entre curvas.

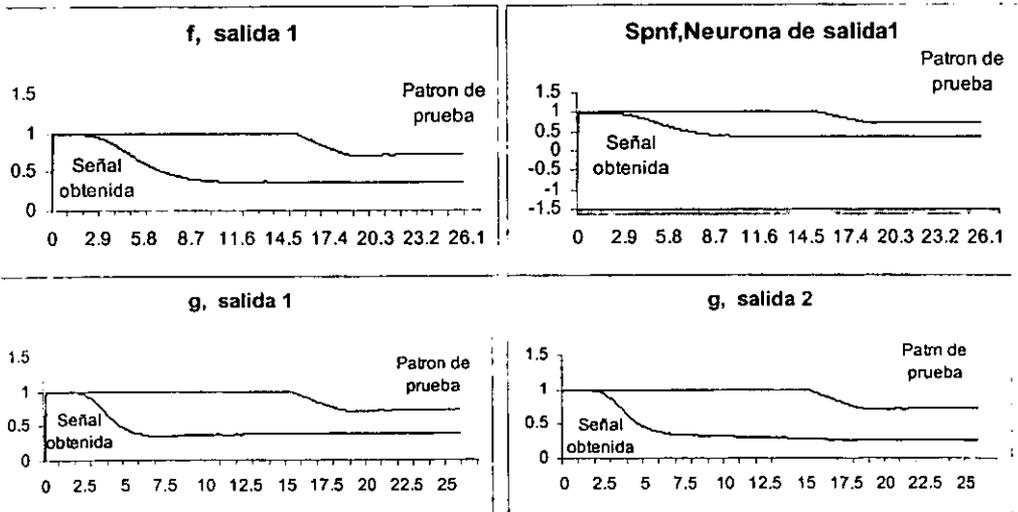


Figura:25 Pruebas fuera de línea de las tres redes entrenadas con cambios progresivos de acuerdo a las pendientes y las alturas entre curvas.

El tiempo de llenado del modelo de entrenamiento, no se ajusta directamente con el tiempo de llenado del compresor.

Por otro lado se trata de investigar la relación que existe con la distancia final de las curvas de error y control y como afecta la pendiente de la exponencial "Tu" cuando se aplica  $T_u=1,2,5.6$ .

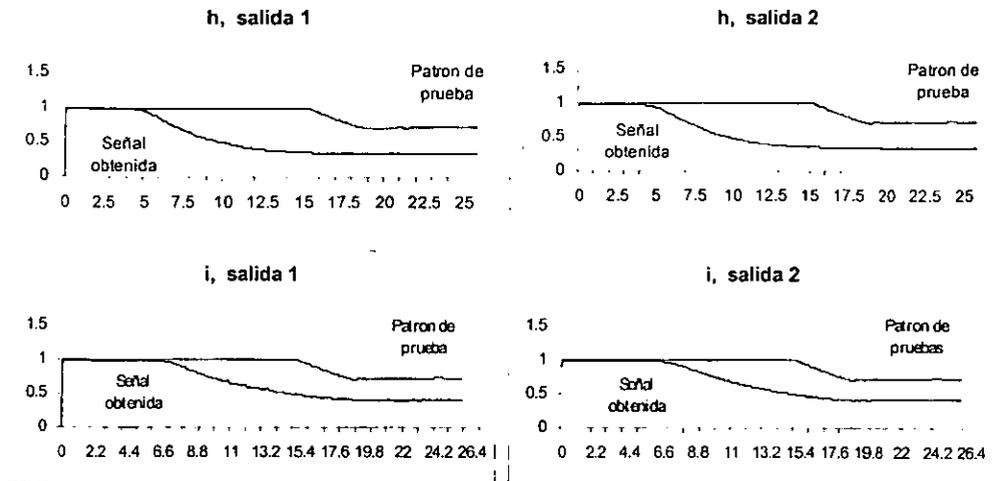


Figura:26 Pruebas fuera de línea de las tres redes entrenadas con cambios progresivos de acuerdo a las pendientes y las alturas entre curvas.

De las gráficas de prueba observamos un incremento en el tiempo del escalón de 8V. A medida que "Tu" es más pequeña las pendientes crecen al aumentar la distancia final entre curvas. El tipo de pendiente no se afecta perceptiblemente por la T. La curva o pendiente de la curva aumenta de tamaño al aumentar la distancia entre curvas, de las señales de prueba. Ahora bien una vez descubierta la utilidad del cruzamiento de parámetros haremos mas amplio nuestro estudio para incluir nuevos parámetros que nos den respuesta a los comportamientos que por observación queremos afectar.

Para ello, con el modelo de curva básica planteado y modificando 4 parámetros podemos hacer una tabla para crear el tipo de controlador neuronal que queremos para resolver las condiciones de respuesta del compresor deseadas.

Para encontrar los parámetros adecuados primero definimos las variables en la pendiente de la curva de primer orden de la señal de control como previamente lo hicimos con la señal de error donde la constante T defina dicha pendiente.

Para explicar este parámetro decimos que la respuesta a un escalón unitario de un sistema de primer orden encontramos que en un tiempo igual a una constante de tiempo  $T_u$ , la curva exponencial de respuesta ha pasado de 0 a 63.2 % del valor final, y para  $5T_u$  la respuesta habrá alcanzado el 99.3% del valor final.

Para encontrar los parámetros que actúan sobre el tiempo de llenado del cilindro de aire del compresor modificamos el intervalo de tiempo que permanece constante la señal de control a un nivel de salida 8v, produciendo un aumento de presión en la salida del compresor. Para encontrar las variables que produce en el controlador neuronal la caída del escalón invertido de la señal de control, cuando el valor final esta presente por el cambio de la constante previa de 8v a 4v nuevo valor menor a este y representado por R2.

Para encontrar las variaciones que produce en el neurocontrolador la distancia final de las curvas de control y error, aproximadas por escalones negativos correspondientes para ambas gráficas calculadas por otro escalón en la señal de error que va desde la referencia mayor R a la referencia menor del escalón invertido R3.

R= referencia de entrada  
 R2= escalón negativo para la señal de control  
 R3= escalón negativo para la señal de error

$$S(t) = R2 + (8 - R2)e^{-t/Ts} \dots(15)$$

$$U(t) = R3 + (R - R3)e^{-t/Ts} \dots(16)$$

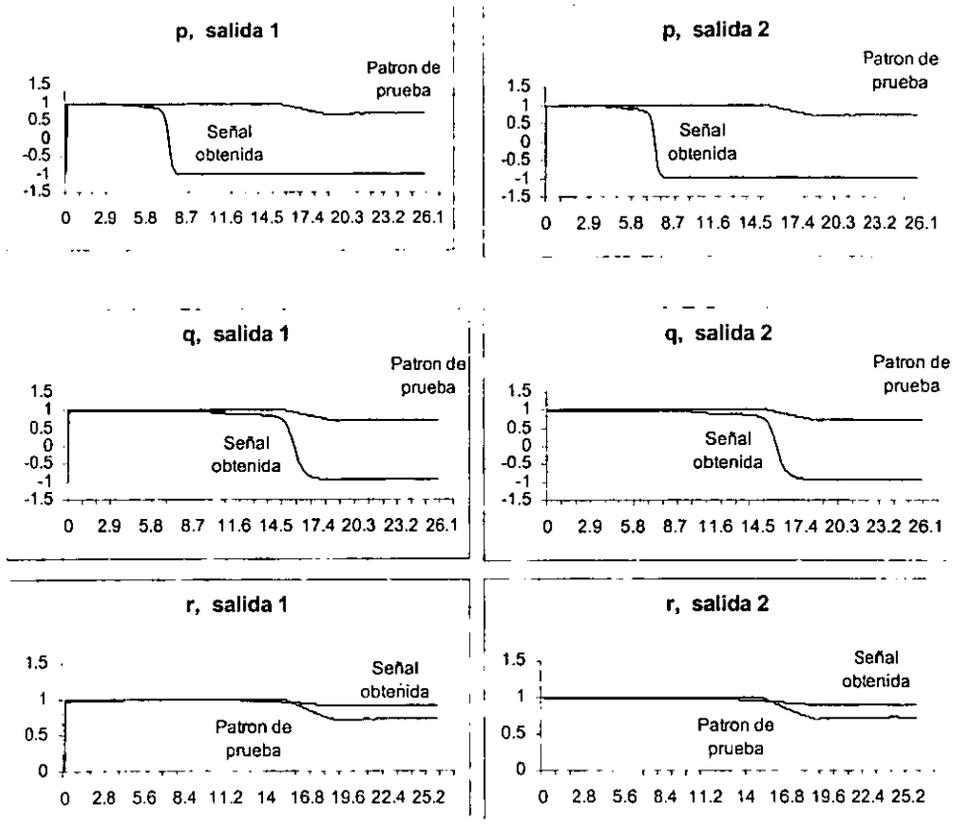


Figura:27 Señales de prueba para las salidas 1 y 2 con condiciones de entrenamiento diferentes

Tomemos las últimas tres plantillas diseñadas y variando la pendiente de la señal de control entre 0 y 10 segundos al 99.3% de establecimiento, es decir, una,  $T < 2$  s.

Por consiguiente podemos crear 9 patrones con características de estudio cruzado como lo hicimos con el grupo anterior: De los resultados obtenidos gráficamente concluimos que a mayor distancia entre las líneas de error y control el tiempo de llenado aumenta, e incluso controla mejor. Para el caso del aumento en  $Ts = \{5, 10, 15\}$  las curvas de prueba resultantes se elevan ligeramente haciendo la pendiente menor a medida que "Ts" aumenta.

Para probar el efecto que producen los cambios en el valor de los parámetros, finalmente construimos un grupo de 81 redes neuronales para definir si los cambios a la plantilla tienen

Un aprendizaje de control predecible con respecto al aumento o disminución de los parámetros siguiente: Tabla 6

$$\begin{array}{lll}
 S_{e_1} = 5 + 3e^{-t/5} & S_{e_2} = 5 + 3e^{-t/5} & S_{e_3} = 5 + 3e^{-t/5} \\
 S_{C_1} = e^{-t/2} & S_{C_2} = -1 + 2e^{-t/2} & S_{C_3} = -2 + 3e^{-t/2} \\
 S_{e_4} = 5 + 3e^{-t/10} & S_{e_5} = 5 + 3e^{-t/10} & S_{e_6} = 5 + 3e^{-t/10} \\
 S_{C_4} = e^{-t/2} & S_{C_5} = -1 + 2e^{-t/2} & S_{C_6} = -2 + 3e^{-t/2} \\
 S_{e_7} = 5 + 3e^{-t/15} & S_{e_8} = 5 + 3e^{-t/15} & S_{e_9} = 5 + 3e^{-t/15} \\
 S_{C_7} = e^{-t/2} & S_{C_8} = -1 + 2e^{-t/2} & S_{C_9} = -2 + 3e^{-t/2}
 \end{array}$$

Así que se puede combinar una distancia entre curvas de error y control grande, con cambios en "Ts" de la señal de control, para mejorar ambos comportamientos.

Seguido de estos análisis producimos otros con cambios en las características de la señal de control al controlar el tiempo del escalón de 8V entre  $0 < T < 2.8$  segundos para una referencia unitaria de entrada.

El siguiente paso fue generar 81 redes neuronales para definir si los cambios practicados en la plantilla tienen un aprendizaje de control predecible con respecto al aumento o disminución de los parámetros siguientes:

Cambiamos el tiempo "T" durante el cual se presentó en la señal de control un escalón de 8V con los siguientes intervalos  $T = \{0.8, 0.4, 0.2\}$  segundos.

Cambiamos la señal de control en el valor final de la exponencial invertida en  $R2 = \{5.5, 6, 7\}$ . Con base a las señales de error generadas en el primer grupo de plantillas de esta sección es decir las señales de la a a la f (tabla 5) combinamos los tres cambios generando un mapa cruzado de 9 señales particularizadas por 9 cualidades específicas haciendo el total de 81 puntos de coincidencia.

Con esta base de redes probamos una referencia 4, dándonos cuenta que las redes que responden muy cercanamente a su valor de entrenamiento que es para una entrada 4 se obtiene una salida de 1 bar de presión, fueron aquellas que contienen los siguientes parámetros cruzados, un tiempo de llenado del compresor de  $t = 4$  con un cambio en el valor final de la señal de control de 8 V a 5.5V. y las redes correspondientes a un tiempo de llenado del compresor  $T = 0.2$  s con un cambio en el escalón negativo de 8V a 5.5V. Lo que quiere decir que de las 81 redes se acercaron 7 de ellas con una forma clara.

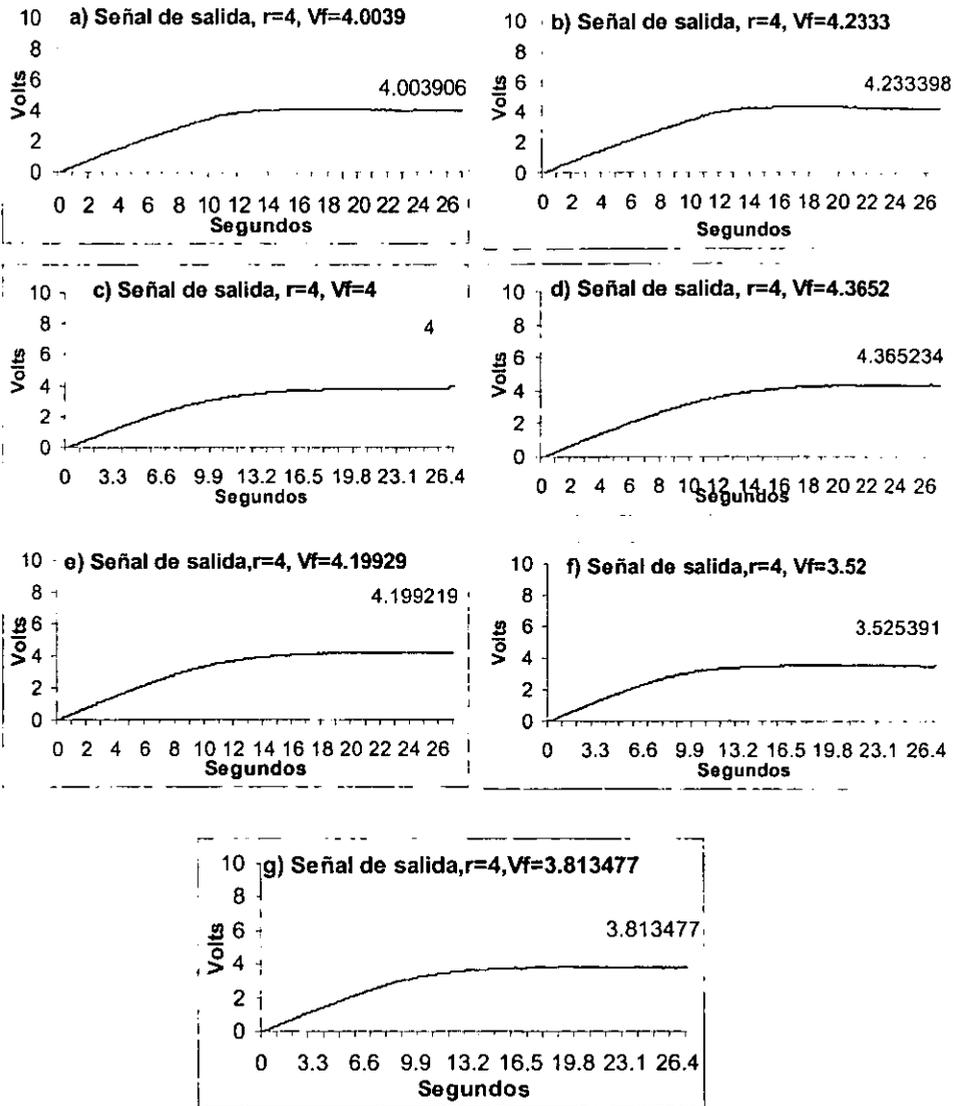


Figura:28 Las redes entrenas son; a) red5, b) red7, c) red31, d) red34, e) red40, f) red58, g) red61. Los resultados encontrados a partir de redes neuronales encontradas con modelos diferentes de los pares de control muestran la respuesta mejorada que responde a una entrada de referencia  $r=4$ , sin producir sobrepaso y alcanzar valores de salida mejores que los encontrados por el PID.

Podemos plantear sin embargo cientos de patrones o características especiales a partir de este modelo como son los tiempos muertos los cuales aparecieron en algunas redes entrenadas con los primeros grupo de datos que contenían nueve gráficos y que al tratar de encontrar sus características en un solo gráfico dimos tumbos sin lograr aun responder esta incógnita, pero es alentador saber que podemos hacer grupos de relación cruzada para estudiar el comportamiento del sistema ante una nueva característica que se intente probar con lo que hemos establecido un método para el estudio de sistemas no lineales y dejamos la base de la plantilla con la que se pueden experimentar transformaciones estables, además debemos agregar que el enfoque final de este tipo de sistema debe llevar a controlar el compresor en todo el campo de medidas lo cual logramos parcialmente, debe lograr alcanzar el nivel de entrada seleccionado lo que se consiguió al alterar los patrones de entrenamiento debe controlar el sobrepaso lo cual mejora con creces el comportamiento del controlador PID, debe responder rápido y lo hace tanto como el sistema lo permite mejorando al PID debido a que requiere menor tiempo de estabilización, es auto ajustable en caso de fallas internas o externas.

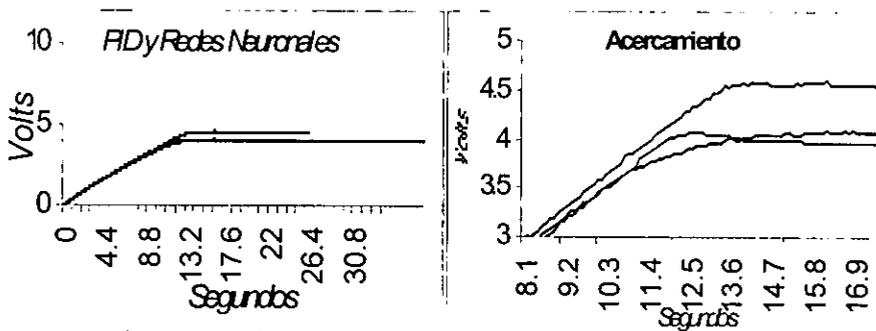


Figura 29. La comparación final con la mejor red neuronal encontrada.

Permite controlar en caso de quererlo la acción de control para que el sistema sufra sobrepasos e incluso oscile. Permite diseñar no solamente el controlador ya que se pueden adherir otras redes para simulación si se quiere eliminar la planta real, se puede diseñar un sistema neurodifuso que dé ordenes de otro nivel de inteligencia artificial, se pueden proponer la investigación del aprendizaje de secuencias de control y en resumidas cuentas creemos que las redes neuronales vienen a darle un nuevo aire al controlador PID ya que no es posible que compitan el uno con el otro mas bien se complementan ya que hemos encontrado en la literatura redes neuronales que utilizan el controlador PID para regular su actividad de aprendizaje.

#### IV. DISCUSIÓN

A medida que el estudio del comportamiento general del compresor avanza y que la respuesta ante la acción de control de la red neuronal era aceptable. Diseñamos las variables que ajustan el sistema neuronal y dichas variables se expresan matemáticamente como sigue [R3,Tu, T, R2]; a partir de la acción que producen los elementos elegidos sobre el entrenamiento de la red y su función en la relación de 2 o mas variables actuando sobre el sistema:

El estudio realizado en esta etapa genero una malla representativa de todas las combinaciones obtenidas después sobre los patrones de entrada salida.

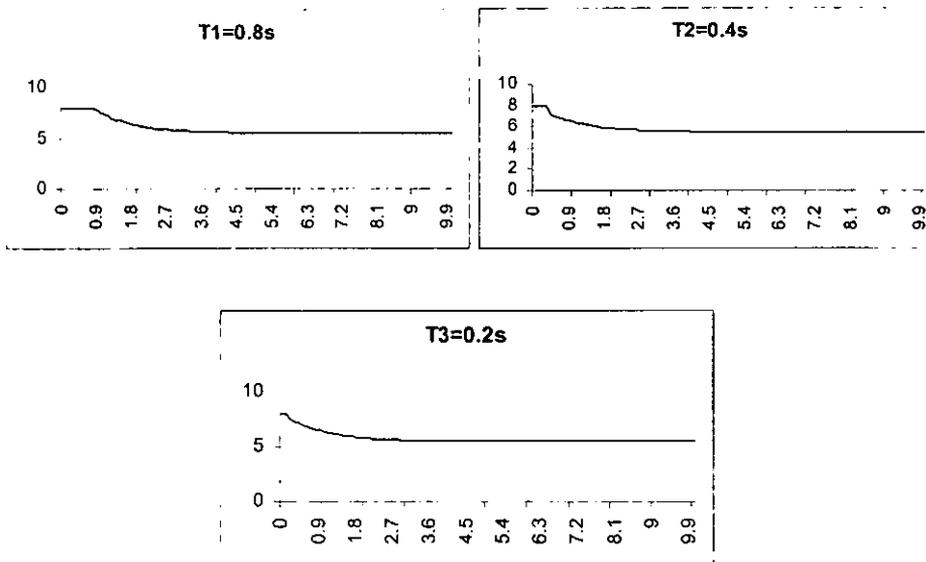


Figura: 30 Variable T (Tiempo de llenado)

La variable aplicada a la señal de control y que representa el tiempo de llenado del cilindro de aire y que controla el tiempo de levantamiento esta propuesto para un  $T = \{ 0.8, 0.4, 0.2 \}$  = { T1, T2, T3 } donde la relación de generalización de la red neuronal se constituye como una relación inversamente proporcional entre el tiempo de llenado y el valor final de la señal de salida del compresor.

Cabe hacer la aclaración de que la premisa para encontrar un valor con el cual pudiéramos calcular una constante para localizar el punto exacto en que el tiempo de llenado del compresor se detuviera para cada referencia no se puede calcular a partir de este parámetro como se pretendía ya que no es el único parámetro que interviene en esta función y no resulta por lo tanto un valor sencillo de encontrar.

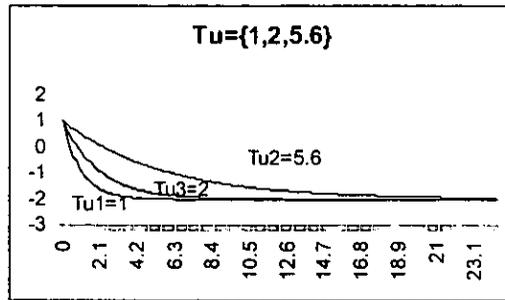


Figura:31 Variable Tu (Pendiente):

La variable aplicada a la señal de error conocida como la pendiente  $Tu$  compresor con valores  $Tu = \{ 1, 2, 5.6 \}$ , actúa de forma que la red neuronal generaliza proporcionalmente al ajuste de la referencia de entrada aplicada.

Observamos que el neurocontrolador con mayor  $Tu$  genera mayor espaciamiento, el valor final de la salida del compresor aumenta a medida que aumenta la referencia de entrada.

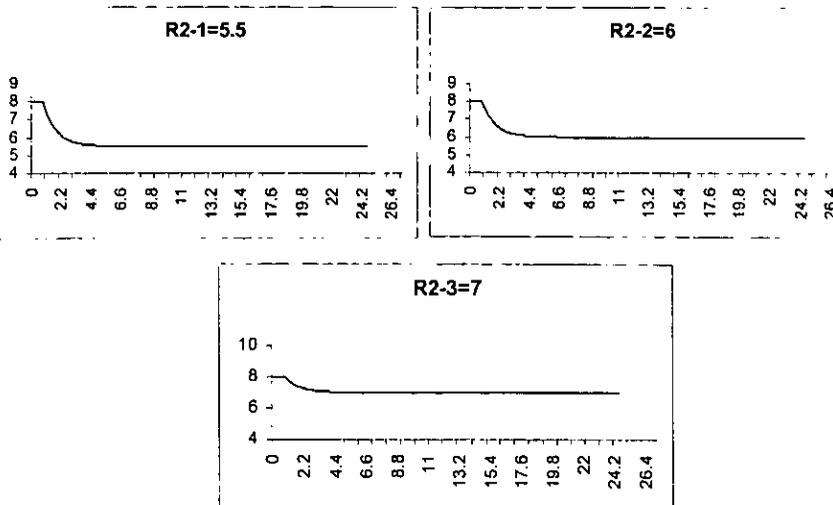


Figura: 32 Variable R2

Cuando hacemos que coincidan  $\{T, R2, Tu\}$  el aumento es proporcional a toda la escala, es decir, no en separación entre valores finales pero si se genera un incremento de magnitud proporcional a toda la escala, independientemente de la separación que existe entre cada valor final representado por la acción de la misma referencia de entrada, por lo que se percibe un incremento en la distancia que hay de la señal de error a la señal de control demostrando que uno contiene un aumento en la variable R3 de 0 a 2 volts de separación con respecto a 0 a 3 volts. La variable que modifica la mejor respuesta del sistema para que el neurocontrolador responda a la referencia de entrada y se pueda obtener la respuesta correspondiente de acuerdo a la tabla de valores entre referencias y presión final esta dada por la variable T que modifica el escalón inicial de la señal de control que permanece durante un tiempo fijo 8v, antes de cambiar al valor de la pendiente de la exponencial del escalón invertido. Como podemos ver la constante nos sirve para las referencias  $r=3$  cuando la constante de inicio es T1,  $r=4$  y  $r=5$  cuando la constante de inicio es T2, y  $r=6$  cuando la constante de tiempo es T3.

Variable a Analizar	Referencia de comparación	Presión final real	Presión final buscada
T1	$r=3$	Pf=0.64 bar	Pf=0.75 bar
T2	$r=4$	Pf=1.03 bar	Pf=1 bar
T2	$r=5$	Pf=1.29 bar	Pf=1.25 bar
T3	$r=6$	Pf=1.53 bar	Pf=1.5 bar

El incremento en la variable de control con respecto a la respuesta de presión final de las redes entrenadas con las ecuaciones siguientes demuestra que a medida que la variable aumenta, también aumenta la ganancia relativa entre las respuestas de salida del compresor, para las mismas señales de entrada o referencia de entrada. Así podemos decir que el grupo de dinámicas de salida incrementan su ganancia sin incrementar la distancia entre cada una de ellas conservando el mismo intervalo de respuesta pero localizándose en una mayor presión de inicio. Sabemos que para T1, T2, y T3 con 0.8, 0.4 y 0.2 segundos respectivamente concluimos que para estos la respuesta del sistema es inversamente proporcional al incremento del tiempo discreto en t, para que el valor de referencia coincida con su valor final de presión a la salida del compresor.

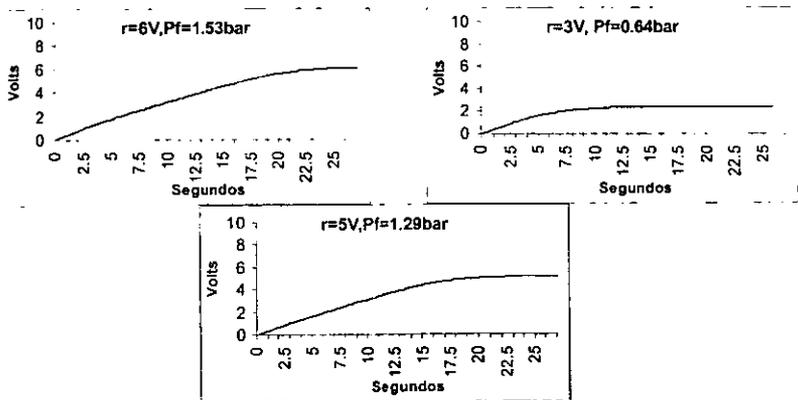


Figura 33. Respuestas comparativas para definir las características de la red neuronal entrenada.

Para este caso se realizaron las comparaciones entre los archivos siguientes:

Para demostrar la función que realiza la variable R2-1, R2-2 y R2-3 basta con echar un vistazo a las primeras referencias de los neurocontroladores, y demostramos que el incremento en la variable también incrementa la escala, aumentando la presión final a la misma referencia,

	R2-1=5.5volts	R2-2=6volts	R2-3=7volts
R=1V	Pf=0.91 bar	Pf=1.68 bar	Pf=1.98 bar
R=2V	Pf=0.92 bar	Pf=1.76 bar	Pf=1.99 bar
R=3V	Pf=1 bar	Pf=1.79 bar	Pf=2 bar

Para R2-1=5.5volts, como parámetro de entrenamiento de la red neuronal, se produce la presión final menor que R2-2, y R2-3.

Para R2-2=6 volts, como parámetro de entrenamiento de la red neuronal, se produce una presión final mayor que R2-1 pero menor que R2-3.

Para R2-3=7 volts como parámetro de entrenamiento para la red neuronal, se produce la presión final mayor de las tres.

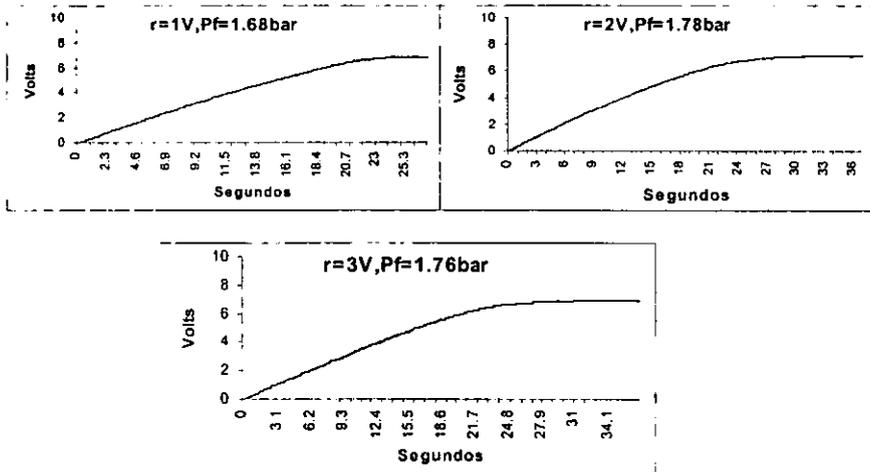


Figura 34. Respuestas comparativas para definir las características de la red neuronal entrenada.

El incremento en la variable R2, mostrado en la tabla muestra claramente como afecta la salida de presión en el sistema neumático, mostrado en las figuras 54, 55 y 56.

	R2-1=5.5volts	R2-2=6volts	R2-3=7volts
R=1V	Pf=1.68 bar	Pf=1.77 bar	Pf=1.84 bar
R=2V	Pf=1.78 bar	Pf=1.79 bar	Pf=1.84 bar
R=3V	Pf=1.76 bar	Pf=1.8 bar	Pf=1.85 bar
R={1 a 8}	Pf=1.68 a 1.79 bar	Pf=1.77 a 1.82 bar	Pf=1.84 a 1.86 bar

La variable R2-1=5.5 produce la presión final menor de las tres variables.

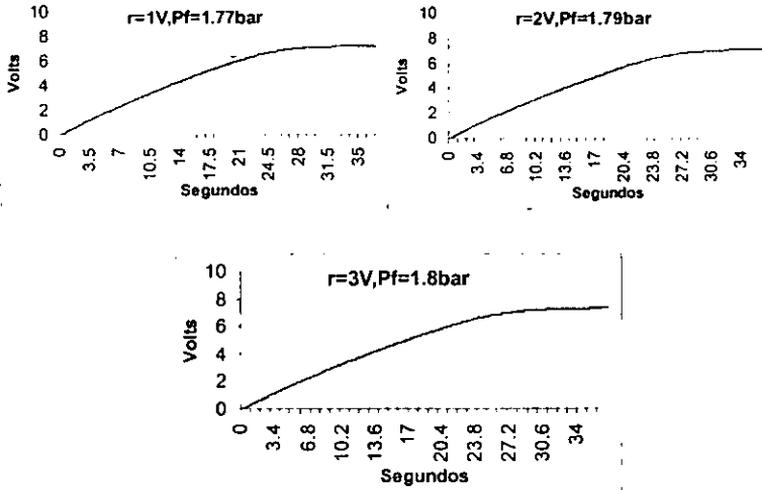


Figura 35. Representación gráfica del comportamiento diferenciado de las características de control no-lineal.

La variable R2-2=6 v produce una presión final mayor que R2-1 pero menor que R2-3.

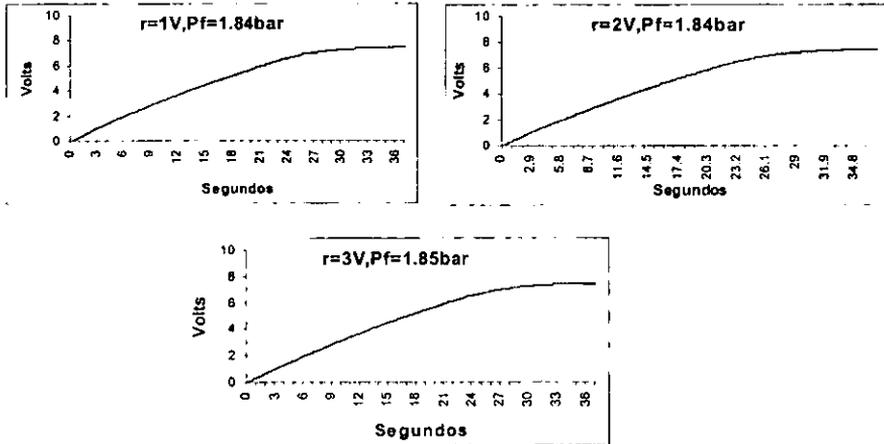


Figura 36. Respuestas comparativas para definir las características de la red neuronal entrenada.

La variable R2-3= 7 v produce la presión final mayor de las tres. El mismo caso se presenta con el entrenamiento de la misma variable con otras condiciones similares para el resto de las variables en estudio. Haciendo que el incremento en la ganancia relativa entre las respuestas de salida del compresor esté de acuerdo con el incremento con la variable en estudio para cada una de las referencias de entrada que controlan la señal de presión final. Por ultimo decimos que en presencia de un incremento de la variable R2 aumenta la escala (R2-3=7) > (R2-2=6) > (R2-1=5.5).

De acuerdo con el análisis gráfico de las respuestas encontradas en la malla de 81 redes neuronales artificiales, podemos separar las respuestas observando el comportamiento de las variables definidas, para conocer el tipo de acción que proporcionan individualmente o en conjunto.

La secuencia de respuestas de la red neuronal artificial fue colocada a partir de la referencia de entrada para el grupo de variables correspondientes desde los limites inferiores a los limites superiores, es decir de cada red entrenada se tomaron las respuestas del sistema a las 8 referencias y se colocaron en una tabla, teniéndose en algunos casos respuestas en todo el intervalo de acción o un intervalo parcial en la mayoría de los casos.

Para el primer grupo tendremos entonces las siguientes características identificadas como red,

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

donde la ecuación representa el cambio en la ecuación original al tener como variables las siguientes:

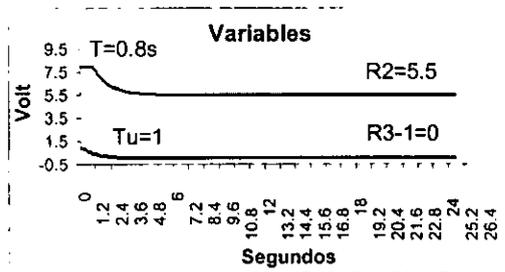


Figura 37. Demostración gráfica de 4 características (T, R2, Tu, R3-1) de las ecuaciones de error y control.

Plantilla con cambios de parámetros para el entrenamiento de una de las 81 redes en la malla de entrenamiento. Las combinaciones siguientes son una muestra de las características que se probaron esperando poder comparar las respuestas que presentan los incrementos y/o disminuciones de las variables.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 6 + 2e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}$$

Como se planteo se generan 81 combinaciones variando un parámetro por vez hasta completar todas las mallas representativas del sistema en estudio.

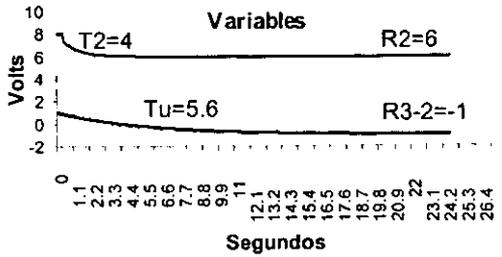


Figura 38. Demostración de cuatro características de las ecuaciones (T, R2, Tu, R3-2) de error y control.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 7+1e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/2)}$$

Otro ejemplo de las características de control de acuerdo a la combinación de variables es el siguiente: Finalmente la combinación número 81 de las redes en entrenamiento:

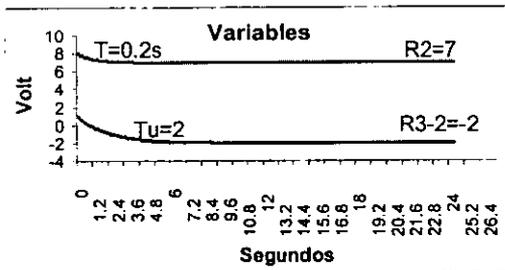


Figura 39. Demostración gráfica de las ecuaciones de (T, R2, Tu, R3-2) error y control.

Plantilla con cambios de parámetros para el entrenamiento de una de las 81 redes.

$$C(t) = R2 + (8 - R2)e^{-t}$$

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ C(t) & \text{si } t > 0.2s \end{cases}$$

$$U(t) = R3 + (R - R3)e^{-(t/Tu)}$$

Las formas en que se pueden presentar las ecuaciones se muestran a continuación: El archivo encontrado con estas características alimentara a la red neuronal para su entrenamiento haciendo uso del procedimiento de entrenamiento como se mostró en el capítulo anterior con un ruido igual a 0.01, siendo entrenada la red a 5000 épocas, teniéndose resultados del error de entrenamiento entre

$$2.11 \times 10^{-4} \quad \text{y} \quad 4.10 \times 10^{-6}$$

Con los neurocontroladores obtenidos grabamos la respuesta de control no lineal para cada una de las referencias de entrada limitadas de 0 a 8 volts, obteniendo como referencia a los resultados los valores finales del sistema, independientemente del análisis posterior de comportamiento particular de cada gráfico en toda la malla de 81 redes y 8 referencias.

Plantilla R3	Tu	T	R2	Plantilla R3	Tu	T	R2	Plantilla R3	Tu	T	R2			
1	0	1	0.8	5.5	28	0	5.6	0.8	5.5	55	0	2	0.8	5.5
2	0	1	0.8	6	29	0	5.6	0.8	6	56	0	2	0.8	6
3	0	1	0.8	7	30	0	5.6	0.8	7	57	0	2	0.8	7
4	0	1	0.4	5.5	31	0	5.6	0.4	5.5	58	0	2	0.4	5.5
5	0	1	0.4	6	32	0	5.6	0.4	6	59	0	2	0.4	6
6	0	1	0.4	7	33	0	5.6	0.4	7	60	0	2	0.4	7
7	0	1	0.2	5.5	34	0	5.6	0.2	5.5	61	0	2	0.2	5.5
8	0	1	0.2	6	35	0	5.6	0.2	6	62	0	2	0.2	6
9	0	1	0.2	7	36	0	5.6	0.2	7	63	0	2	0.2	7
10	-1	1	0.8	5.5	37	-1	5.6	0.8	5.5	64	-1	2	0.8	5.5
11	-1	1	0.8	6	38	-1	5.6	0.8	6	65	-1	2	0.8	6
12	-1	1	0.8	7	39	-1	5.6	0.8	7	66	-1	2	0.8	7
13	-1	1	0.4	5.5	40	-1	5.6	0.4	5.5	67	-1	2	0.4	5.5
14	-1	1	0.4	6	41	-1	5.6	0.4	6	68	-1	2	0.4	6
15	-1	1	0.4	7	42	-1	5.6	0.4	7	69	-1	2	0.4	7
16	-1	1	0.2	5.5	43	-1	5.6	0.2	5.5	70	-1	2	0.2	5.5
17	-1	1	0.2	6	44	-1	5.6	0.2	6	71	-1	2	0.2	6
18	-1	1	0.2	7	45	-1	5.6	0.2	7	72	-1	2	0.2	7
19	-2	1	0.8	5.5	46	-2	5.6	0.8	5.5	73	-2	2	0.8	5.5
20	-2	1	0.8	6	47	-2	5.6	0.8	6	74	-2	2	0.8	6
21	-2	1	0.8	7	48	-2	5.6	0.8	7	75	-2	2	0.8	7
22	-2	1	0.4	5.5	49	-2	5.6	0.4	5.5	76	-2	2	0.4	5.5
23	-2	1	0.4	6	50	-2	5.6	0.4	6	77	-2	2	0.4	6
24	-2	1	0.4	7	51	-2	5.6	0.4	7	78	-2	2	0.4	7
25	-2	1	0.2	5.5	52	-2	5.6	0.2	5.5	79	-2	2	0.2	5.5
26	-2	1	0.2	6	53	-2	5.6	0.2	6	80	-2	2	0.2	6
27	-2	1	0.2	7	54	-2	5.6	0.2	7	81	-2	2	0.2	7

Así pues, los archivos analizados de cada punto en la malla se verán en el ejemplo a continuación, la red entrenada con las ecuaciones siguientes responde:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

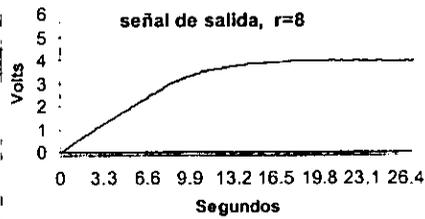
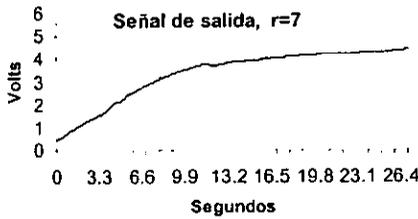


Figura:40 r=1 Presión final = 0.22 bar

Figura:41 r=2 Presión final = 0.20 bar

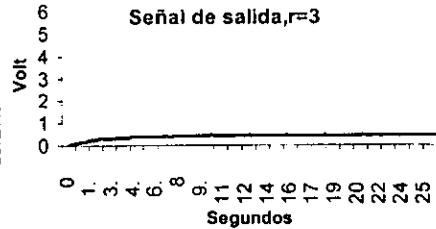


Figura:42 r=3 Presión final = 0.17 bar

Figura: r=4 Presión final = -----

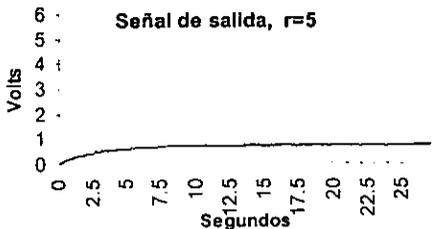


Figura:43 r=5 Presión final = 0.22 bar

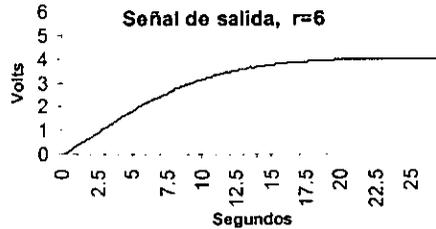


Figura:44 r=6 Presión final = 0.99 bar

Las respuestas de las redes entrenadas con distintas características de entrenamiento que aquí se muestran, son resultado del valor de referencia a la entrada de la red que actúa sobre el sistema dándonos los valores finales de presión que es el parámetro de comparación entre ellas.

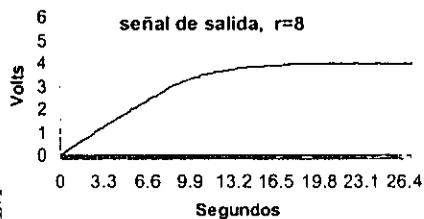
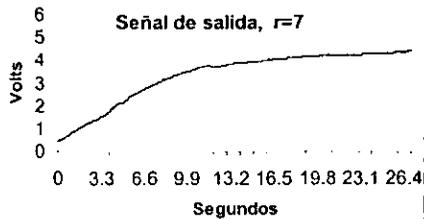


Figura:45  $r=7$  Presión final = 1 bar

Figura:46  $r=8$  Presión final = 1 bar

Genera los siguientes comportamientos de acuerdo a la referencia elegida en cada caso para  $r=\{1, 2, 3, 5, 6, 7, 8\}$ .

Ahora bien nótese que deliberadamente hemos olvidado la referencia 4 ya que dicha referencia toma un análisis especial, describamos a continuación el porque la hemos separado.

#### IV.1.1 Análisis del centro de la escala.

El centro de la escala de presión del campo de medidas se encuentra a 1 bar, y tomando como base las simulaciones de control lineal, tenemos que para obtener este valor debemos colocar una referencia de entrada también a la mitad de la escala de entrada, es decir 4 Volts de referencia, así tenemos que los valores mas cercanos son (Ver figura 34):

Tabla 8

Red5 $r=4$ V	Pf=1.00 bar	Red7 $r=4$ V	Pf=1.08 bar
Red31 $r=4$ V	Pf=0.97 bar	Red34 $r=4$ V	Pf=1.10 bar
Red40 $r=4$ V	Pf=1.03 bar	Red58 $r=4$ V	Pf=0.90 bar
Red61 $r=4$ V	Pf=0.90 bar		

Como se ve en los valores finales de presión las pruebas a  $r=4$ , los patrones que mas se acercaron a  $Pf=1.00$  bar están contenidas en los archivos cuyas características responden a las combinaciones  $[T=0.4, R2=5.5]$  y  $[T=0.2, R2=5.5]$  que representan el tiempo que permanece la señal a 8V y el valor final al que llega la exponencial decreciente en la señal de control respectivamente, estos resultados los analizaremos en la parte final del capítulo.

El procedimiento de comparación entre los neurocontroladores se lleva a cabo al tomar los grupos correspondientes a cada referencia, así comparamos la respuesta de cada neurocontrolador a una referencia de entrada (de acuerdo con la tabla 9)

Tabla 9

R=1V	Pf=0.25 bar	R=2 V	Pf=0.50 bar
R=3 V	Pf=0.75 bar	R=4 V	Pf=1.00 bar
R=5 V	Pf=1.25 bar	R=6 V	Pf=1.50 bar
R=7 V	Pf=1.75 bar	R=8 V	Pf=2.00 bar

donde las diferencias de efectos de cada una de las doce variable en estudio serán marcadas por el incremento o decremento del efecto mas notorio, por ejemplo, los aumentos en el valor final de presión, que es la referencia mas directa haciendo uso exclusivamente del manometro.

---

Los efectos gráficos del comportamiento del sistema controlado no linealmente se hacen a continuación.

#### IV.1.2 Plantillas entrada-salida No útiles para el análisis gráfico

Con las respuesta de presión de los primeros elementos contenidos en el conjunto de las variables en sus valores inferiores tenemos respuesta sobre toda la escala o campo de medidas, por el contrario en los últimos elementos contenidos en el conjunto de las variables en sus valores superiores, las escalas sobrepasan el campo de medidas, es decir los 2 bar, así que a partir de la red45 desconocemos la respuesta del neurocontrolador a casi toda referencia de entrada, es el caso de las siguientes neuroredes, cuyas combinaciones hacen 15 redes.

#### IV1.3 Plantillas entrada-salida útiles para el análisis gráfico

Junto con los 8 neurocontroladores que solo responden a la mitad de las referencias de entrada es decir de una referencia menor a 6. Tanto para las primeras 15 redes como para las segundas 8 redes entrenadas podemos decir que limitan los estados de inestabilidad y que las combinaciones que van en la misma tendencia de variables encontraran estados inestables de las redes sin la necesidad de entrenar los neurocontroladores, de ahí que la malla nos puede limitar el comportamiento a investigar.

Al revisar cuidadosamente cada respuesta separamos las redes que nos pueden servir al adentrarnos a un análisis mas profundo ya que de esta forma hemos eliminado un buen número de neurocontroladores poco o nada funcionales, para dejar los que nos van a servir para comprobar el funcionamiento de la malla de 81 neurocontroladores.

Como ya hemos visto la comparación de respuestas del neurocontrolador será referencia por referencia, a partir del incremento o decremento de la variable en estudio.

Veamos entonces como afecta cada variable y tratemos de generalizar el comportamiento que produce dicha variación.

##### IV1.3.1Primer Caso

Para el caso de un voltaje de entrada  $r=1V$  y una respuesta de la presión a 0.25 bar buscamos en las listas de archivos y obtenemos las siguientes combinaciones:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

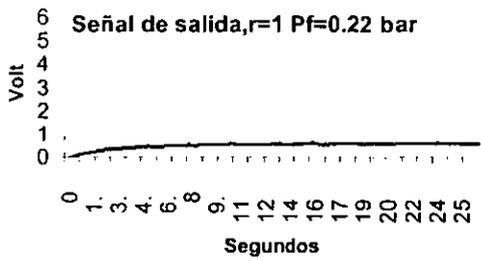


Figura 47. Respuesta comparativa para la salida de presión con respecto a la referencia de entrada.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores, (Referencia 1 volt, Presión Final 0.22 bars).

IV1.3.2 Segundo Caso

Para una referencia de entrada igual a 2 y todas las respuestas de salida a 0.5 bar tenemos:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

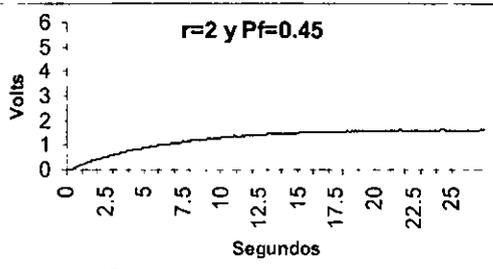


Figura 48. Respuesta ideal a la referencia de entrada y salida de presión.

Tenemos respuesta a las siguientes referencias de entrada, a la neurored con las características anteriores(Referencia 2 volts, Presión final 0.45 bars).

IV.1.3.3 Tercer Caso

Continuemos separando las redes de acuerdo a la tercer clasificación r=3V a una presión de salida 0.75 bar.

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

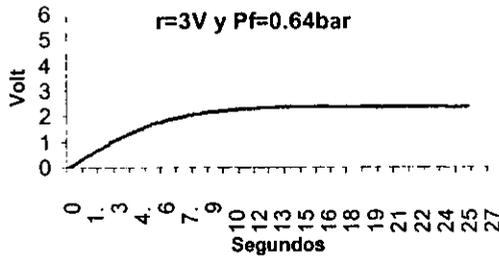


Figura 49. Respuesta a la referencia de entrada para una salida de presión buscada.

La respuesta a las siguientes referencias de entrada a la red con las características anteriores (Referencia 3 volts, presión final 0.64 bars).

#### IV1.3.4 Cuarto Caso

Para la mitad de la escala la cual es una de las respuestas mas importantes de analizar tenemos  $r=4V$  y con una salida a 1 bar.

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

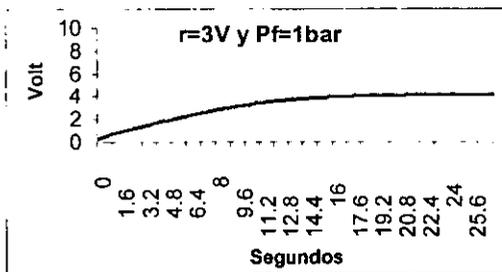


Figura 50. Salida comparativa de la señal de error, respecto a la salida de presión.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 3 volts, Presión final 1 bar).

IV.1.3.5 Quinto Caso

Para encontrar la presión a 1.25 bar a partir de la referencia 5 volts, tenemos:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

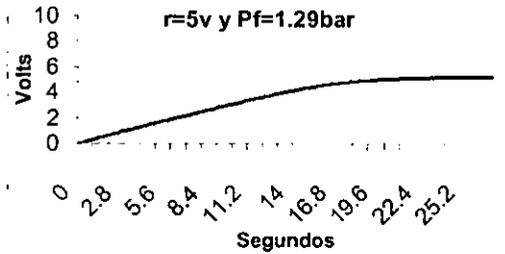


Figura 51. Respuesta del sistema a la referencia de entrada y salida ideal.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 5 volts, Presión final 1.29 bars).

IV.1.3.6 Sexto Caso

Con la misma forma de análisis para r=6V y 1.5 bar de presión, veremos que:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 6 + 2e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

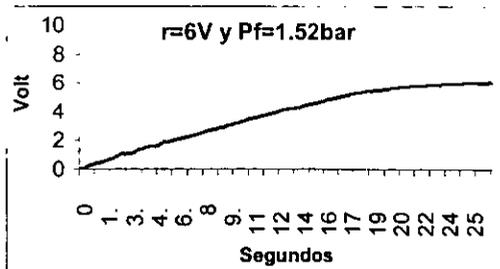


Figura 52. Respuesta de la señal de entrada a la referencia ideal.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 6 volts, Presión final 1.52 bares).

#### IV.1.3.7 Séptimo Caso

Del grupo que cumplen para la siguiente referencia  $r=7V$  y  $Pf=1.75$  bar tendremos:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

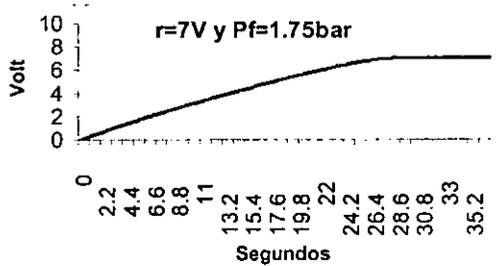


Figura 53. Entrada y Salidas buscadas como condiciones ideales.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 7 volts, Presión final 1.75 bares).

#### IV.1.3.8 Octavo Caso

Por último para la combinación de entrada a  $r=8V$  y salida  $Pf=2$  bar encontramos:

Para el archivo neurocontrolador, representado por la combinación de las señales de error y control respectivamente representadas por las ecuaciones siguientes:

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (referencia 8 volts, presión final 2.02 bars).

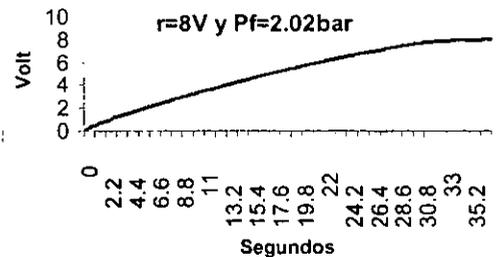


Figura 54. Respuesta ideal de referencia de entrada y valor final de presión.

---

## V. Valores Finales Ideales

Hagamos ahora alguna selección de respuestas que mejor se ajustan como la red5 [T=0.4, R2=6, R3=0, Tu=1], con referencia r=1V valor de salida buscados,

Por ejemplo si buscáramos respuestas para cada entrada aunque tuviéramos que tomar una plantilla entrada-salida para cada respuesta, requeriríamos de un paso adicional de programación para seleccionar el mejor caso, dicho paso de programación podría suplirse con funciones lógicas, o presenta la posibilidad de trabajar el sistema con redes neurodifusas así pues presentamos una selección de archivos con los que se podría tratar este enfoque:

Fijemos la atención en los valores de presión final, como se podrá notar hay que salvar el problema de las diferentes referencias de entrada, así que se tiene que agregar un sistema antes del control neuronal que permita hacer los cambios de voltaje de la referencia independientemente del valor al que se encuentre el lazo de realimentación lo cual indicaría una fuente diferente de control alterándose la composición del modelo planteado.

V.2.1.- La referencia que concuerda con el valor final de presión Pf=0.25 bar es 5v, y al ser diferente de una de 1v, planteamos una aplicación del neurocontrolador donde la señal de entrada puede ser diferente de la condición de salida buscada.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 6 + 2e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = e^{-t}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 5 volts, Presión final 0.25bar).

V.2.2.- La referencia que concuerda con el valor final de presión Pf= 0.5bar es 3v, que es una red diferente a la de la primera referencia para valor final, así que podemos seguir buscando las mejores respuestas de presión final para cada referencia.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 3 volts, presión final 0.5 bars).

V.2.3.-La referencia que concuerda con el valor final de presión Pf=0.75 bar es 2v, y nos muestra que distintas redes entrenadas pueden mejorarse entre sí para algunos valores de respuesta, así que podemos separar resultados mejores en cada uno de los parámetros del compresor.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = e^{-(t/2)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 2 volts, presión final 0.74 bars).

V.2.4.- La referencia que concuerda con el valor final de presión  $P_f=1$  bar es 4v, y podemos ver que se ajusta a los centros de escala concordando con la entrada y la salida buscadas.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 7+1e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 4 volts, Presión final 1 bar).

V.2.5.- La referencia que concuerda con el valor final de presión  $P_f= 1.25$  bar es 8v, podemos notar que las respuestas obtenida de las redes entrenadas con una señal de error como la de los casos 1,2,4 y 5 muestran los comportamientos buscados.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 7+1e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-t}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 8 volts, Presión final 1.25 bars).

V.2.6.- La referencia que concuerda con el valor final de presión  $P_f=1.5$  bar es 9v, con cada nueva red encontramos resultados diferentes para los valores buscados.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (referencia 9 volts, Presión final 1.5 bars).

V.2.7.- La referencia que concuerda con el valor final de presión  $P_f=1.75$ bar es 6v, notamos que la red neuronal generaliza con valores muy cercanos a los esperados por el modelo de señales de entrenamiento por el que pequeñas variaciones en los mejores casos nos pueden conducir a mucho mejores resultados.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 6 volts, Presión final 1.75 bars).

La referencia que concuerda con el valor final de presión Pf=1.75 bar es 7v, como ya dijimos cambios en las variables modifican el comportamiento mejorando los resultados.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 7 volts, Presión final 1.75 bars).

V.2.8.- La referencia que concuerda con el valor final de presión Pf=2 bar es 9v, teniendo resultados cercanos es mas fácil buscar cambios en los parámetros de entrenamiento

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 6 + 2e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = e^{-(t/2)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 9 volts, Presión final 2 bars).

La referencia que concuerda con el valor final de presión Pf=2bar es 1v.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 7 + 1e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores (Referencia 1 volt, Presión final 2 bar).

La referencia que concuerda con el valor final de presión Pf=2bar es 6v

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características anteriores(Referencia 6 volts, Presión final 2 bar).

Por el contrario de lo que se esperaría con un sistema lineal nos muestra la capacidad no lineal de responder a referencias completamente diferentes ante la misma salida esperada, abriéndonos nuevas posibilidades de resolución del problema.

### V.3 Neurocontroladores de mayor campo de medidas.

A continuación seamos mas estrictos en la descripción de las respuestas apejándonos a la forma lineal que nos ha servido de guía:

Tabla 10

Referencia	Plantilla	Presión final	Presión Ideal
1 v	1	0.22 bar	0.25 bar
2 v	2	0.45 bar	0.50 bar
3 v	37	0.64 bar	0.75 bar
3 v	58	0.88 bar	0.75 bar
4 v	28	0.97 bar	1 bar
4 v	4	1 bar	1 bar
4 v	40	1.03 bar	1 bar
4 v	31	0.97 bar	1 nar
4 v	7	1.08 bar	1 bar
4 v	34	1.1 bar	1 bar
5 v	40	1.29 bar	1.25 bar
5 v	34	1.1 bar	1.25 bar
6 v	8	1.44 bar	1.5 bar
6 v	35	1.52 bar	1.5 bar
6 v	43	1.543 bar	1.5 bar
7 v	46	1.74 bar	1.75 bar
7 v	52	1.75 bar	1.75 bar
8 v	44	2.03 bar	2 bar
8 v	62	1.97 bar	1 bar

Las combinaciones que se muestran en la tabla 10 son aquellas que se cumplen para mas de una referencia, es decir que un mismo neurocontrolador actúa en mas de un caso de acuerdo a la relación con que hemos venido comparando las entradas y las salidas es decir por cada Volt de entrada obtenemos un aumento en la presión de salida de 0.25bar.

El valor de la referencia dentro del cuadro indica el valor final al que se ajusta en la escala de incrementos de 0.25 bares por unidad.

En la tabla 10 encontramos 16 redes que representan todas las funciones que estamos buscando, correspondientes tanto a la entrada como a la salida.

Con estos resultados y haciendo un recuento de las redes cuyo crecimiento es progresivo en el valor final con respecto a la referencia de entrada encontramos que las plantillas de entrada-salida que contienen la exponencial decreciente con  $[R3=0, Tu=1]$  quedan eliminados de la selección ya que en estos casos su forma de control requiere de una forma especial, así que dejemos a un lado este grupo de redes y analicemos el resto de las redes que nos lleva a obtener nueve redes con mejores características de control y que se ajustan al modelo con que hemos estado trabajando, sin que esto quiera decir que las redes que hemos dejado fuera no cumplan con su función de controlar al sistema.

Hasta aquí concluimos una perspectiva del uso de las redes neuronales a partir de nueve redes para conseguir todas las respuestas de los neurocontroladores a las señales buscadas.

La lista de neurocontroladores que se van a revisar se a tomado en cuenta que ocupen el mayor intervalo de control respectivamente, ya que se a puesto la atención sobre todas las respuestas de referencia y especialmente su aumento progresivo en el valor final, a cada nuevo incremento en la referencia de entrada.

El intervalo para la red entrenada con estas ecuaciones abarca una  $Pf=1.76$  bar al inició de las respuesta y una  $Pf=1.81$  bar las respuestas.

Comparando 49 redes entrenadas con la presión del valor final desde la referencia de entrada inicial 1v hasta 8v, cuyos intervalos de presión alcanzan la mayor separación de presión correspondiendo al incremento de referencia y por consiguiente la mayor

separación entre la presión de inicio y la presión alcanzada con la última referencia. La separación entre estas presiones representa una familia de dinámicas separadas entre si un determinado incremento de presión y cuyo incremento máximo es el que analizamos. para determinar las características del controlador con respecto a otros controladores entrenados con patrones de entrenamiento diferentes.

Se han eliminado los neurocontroladores con [R3=0, Tu=1], [R3=-1, Tu=1], [R3=-2, Tu=2] quedando las combinaciones mas favorables al estudio

$$[T=0.4s, R2=5.5]$$

$$[T=0.8s, R2=6]$$

$$[T=0.2s, R2=5.5]$$

donde la señal de [R3=0, Tu=5.6] podría reemplazar a los conjuntos que se pierden al eliminar la señal [R3=0, Tu=1], se ve que hay repetición con las combinaciones

$$[T=0.4s, R2=5.5]$$

$$[T=0.2s, R2=5.5]$$

del siguiente grupo, del cual reducimos a tres intervalos en el campo de medidas:

Del universo de respuestas encontradas mostramos los resultados de las redes para ir acotando y comparando las señales obtenidas con las ecuaciones que permiten dichas respuestas, así iremos clasificando las respuestas de salida de acuerdo a las combinaciones exitosas y descartando las combinaciones más alejadas de las respuestas buscadas.

Las combinaciones de respuestas para las redes entrenadas muestran comportamientos predecibles de acuerdo con las modificaciones realizadas en las ecuaciones de entrenamiento por lo que podemos hacer la separación de estas redes a partir de los datos de entrenamiento de la red neuronal y la comparación entre las distintas redes entrenadas por la respuesta proporcionada al interactuar con el compresor y responder a las referencias de entrada predeterminadas. Del grupo de respuestas a cada una de las referencias de entrada se genera una familia de dinámicas de salida dada por un neurocontrolador. La separación entre dinámicas generadas proporciona un método de comparación tanto la separación por si mismo, como la escala en la cual actúa. Considerando que no todas las redes responden a valores de presión final en el mismo intervalo, definimos que de todo el campo que va de 0 a 2 bar de presión encontramos distintos niveles de respuesta de las redes entrenadas ya que sólo responden a intervalos menores.

Los intervalos de respuesta son entonces clasificados para tres grupos donde las redes responden al valor de referencia inicial y hasta el valor de referencia final de acuerdo con esto: 1....- De 1.33 bar a 2bar, 2.- De 0 bar a 1.58 bar y 3.- De 0.87 bar a 1.68 bar.

V3.1 El primer intervalo de 1.33 bar a 2 bar tenemos:

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.55 bar, Presión final máxima 1.91 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -2 + 3e^{-t}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes(Presión final mínima 1.33 bar, Presión final máxima 1.97 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

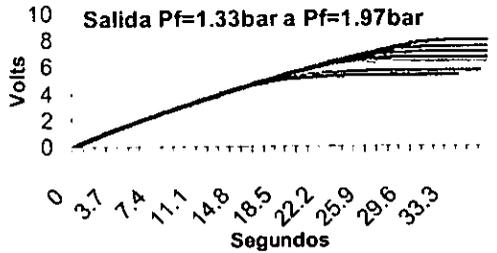


Figura 55. Salidas de presión en el intervalo alcanzado por las condiciones de control no-lineal.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.34 bar, Presión final máxima 1.81 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.52 bar, Presión final máxima 1.93 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = -2 + 3e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.58 bar, Presión final máxima 2.02 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

V.3.2 El segundo grupo que va de 0 bar a 1.58 bar: Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0.84 bar, Presión final máxima 1.3 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0 bar, Presión final máxima 0.99 bar).

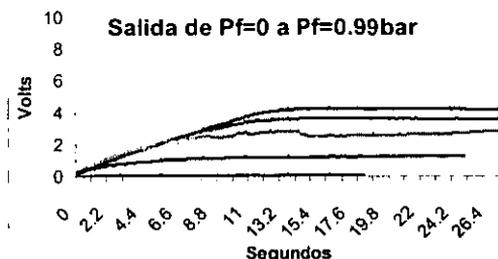


Figura 56. Intervalo de presión alcanzado por las condiciones de control no-lineal.

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0.21 bar, Presión final máxima 1.14 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.25 bar, Presión final máxima 1.57 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 6 + 2e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0.91 bar, Presión final máxima 1.5 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0.63 bar, Presión final máxima 1.58 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.4s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.4s \end{cases}$$

$$U(t) = e^{-(t/2)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 0.43 bar, Presión final máxima 1.42 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

V3.3 Por ultimo el tercer grupo se encuentra en el intervalo de 0.87 bar a 1.68 bar: Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (presión final mínima 0.87 bar, Presión final máxima 1.67 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 7 + 1e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.1 bar, Presión final máxima 1.66 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

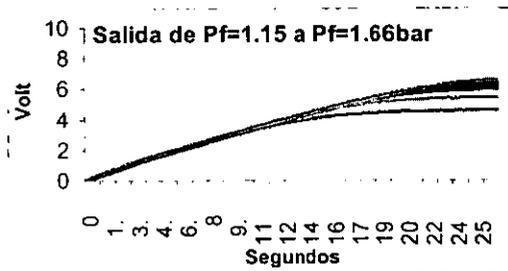


Figura 57. Intervalo de presión representado por las condiciones de control no-lineal.

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.15 bar, Presión final máxima 1.66 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = -1 + 2e^{-(t/5.6)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.1 bar, Presión final máxima 1.68 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.8s \\ 6 + 2e^{-t} & \text{si } t > 0.8s \end{cases}$$

$$U(t) = e^{-(t/2)}(v)$$

Tenemos respuesta a las siguientes referencias de entrada, a la red con las características siguientes (Presión final mínima 1.01 bar, Presión final máxima 1.64 bar).

$$S(t) = \begin{cases} 8(v) & \text{si } t < 0.2s \\ 5.5 + 2.5e^{-t} & \text{si } t > 0.2s \end{cases}$$

$$U(t) = e^{-(t/2)}(v)$$

Las combinaciones que se repiten en ocho redes entrenadas red28, red43, red46, red52, red31, red35, red43, red58

Nuevamente diremos que los tres grupos de neurocontroladores se comportan aumentando progresivamente en el valor final, respecto de la señal de referencia, y cubren un intervalo de medidas mayor.

---

## VI. Conclusiones

A lo largo de este trabajo experimental hicimos diversas reflexiones que nos permitieron conocer el comportamiento de las redes neuronales y su utilidad como tecnología de aplicación.

Desde el punto de vista de la Ingeniería las redes neuronales nos han servido para controlar sistemas dinámicos en el tiempo, con la ventaja de no requerir un modelo matemático para su entrenamiento, como es el caso del control.

Desde la opinión de las matemáticas lineales las redes neuronales están consideradas como filtros no-lineales, ya que surgen de representaciones de filtros FIR, y IIR, y su teoría nos sirve para definir ciertos parámetros.

Desde la opinión de los programadores estos sistemas apenas comienzan su desarrollo el cual estuvo estacionado, ya que dependen de la evolución de la electrónica a gran escala, y es ahí donde se insertan los nuevos usos de las redes neuronales.

Personalmente en el campo de trabajo he encontrado que los desarrollos con redes neuronales se comienzan a ver en las paqueterías y los sistemas de control, tanto en PLC, como en tarjetas de desarrollo, para la aplicación e investigación respectivamente.

Este trabajo nos ha mostrado que la tecnología digital que emplea necesita de una alta capacidad de respuesta, y que a su vez permite una respuesta rápida, tanto a problemas de filtrado, y tiempo continuo, como a problemas discontinuos donde se presentan elementos discontinuos o aleatorios.

Para el contexto general del trabajo debemos pensar que cualquier universo de patrones de señales pueden ser aprendidos por una red neuronal siempre y cuando se puedan tener una señal de entrada y una señal de entrenamiento, por lo que resulta casi natural el decir que en un lazo de control podemos poner una red neuronal a la entrada de la planta como controlador, a la salida de la planta como filtro, en el lazo de realimentación, alimentando cualquiera de los lazos a partir de la simulación de la planta como elemento de corrección, prealimentando una red neuronal con la misma entrada de la planta como simulación, prealimentando una red neuronal con la salida-entrada de la planta en la entrada-salida de la red, o poniendo a la red como modelo de entrenamiento de una segunda red que comparta entrada y salida de la planta para eliminar los factores internos de esta.

La variedad de modelos que se pueden obtener para resolver un problema nos lleva definir redes neuronales capaces de un aprendizaje directamente del sistema en estudio que cada vez es más empleado en la industria y que se espera un incremento fuerte en México en el corto plazo con la entrada de maquilas electrónicas y el apoyo de convenios universidad industria como se dan en el extranjero como España.

A largo plazo se espera que muchas de estas aplicaciones tecnológicas puedan sustituir a las actuales en procesos donde los controles son todavía humanos, y en la espera del desarrollo de la nanorobotica donde el uso de redes neuronales ocupa un menor espacio en comparación con una programación tradicional, su talón de Aquiles sigue siendo el proceso de entrenamiento en cuyo desarrollo se sigue investigando.

Se espera que el desarrollo en tecnología óptica aumente las posibilidades de generar estructuras tridimensionales con una densidad mucho mayor y una interconectividad mayor que lo que ofrece una sola dirección polarizada, en sustratos de silicio.

---

## VI.1 BIBLIOGRAFIA

1.-

David E. Rumelhart, James L. Mc Clelland  
Parallel Distributed Processing  
Explorations in Microstruture of Cognition

2.-Timothy Masters

Practical Neural Network Recipes in C++

3.-Russell C. Eberhart

Roy W. Dobbins

Neural Network PC Tools

A practical Guide

4.-The official Journal of the International Neural Network Society

April 1996

5.-

Frequently Ask Questions

What is a neural network(NN)?

Subject: What are the population, sample, training set, design set, validation set, and test set?

Frequently Ask Questions2

Subject: How many learning methos for NN's exist? Which?

Subject: What is backprop?

Subject: Why use activation function?

Subject: Should I normaliza/ standardize/ rescalete the data?

6.-DynaMind

DEVELOPER USER'S GUIDE

1992 NeuroDynamX, Inc.

7.-Patrick Henry Wiston (professor of computer science Director, Artificial Intelligence

Laboratory Massachusetts Institute of Technology)

Artificial Intelligence

Third Edition

Addison-Wesley Publishing Company 1992

8.-Robert Hecht-Nilsen (HNC, Inc. and University of California, San Diego)

Addison-Wesley Publishing Company 1991

Neurocomputing

9.-James A. Freeman

David M. Skapura

Neural Networks Algorithms, Aplications and Programming Techniques.

---

## VI.1 BIBLIOGRAFIA

1.-

David E. Rumelhart, James L. Mc Clelland  
Parallel Distributed Processing  
Explorations in Microstruture of Cognition

2.-Timothy Masters

Practical Neural Network Recipes in C++

3.-Russell C. Eberhart

Roy W. Dobbins

Neural Network PC Tools

A practical Guide

4.-The official Journal of the International Neural Network Society

April 1996

5.-

Frequently Ask Questions

What is a neural network(NN)?

Subject: What are the population, sample, training set, design set, validation set, and test set?

Frequently Ask Questions2

Subject: How many learning methos for NN's exist? Which?

Subject: What is backprop?

Subject: Why use activation function?

Subject: Should I normaliza/ standardize/ rescalete the data?

6.-DynaMind

DEVELOPER USER'S GUIDE

1992 NeuroDynamX, Inc.

7.-Patrick Henry Wiston (professor of computer science Director, Artificial Intelligence

Laboratory Massachusetts Institute of Technology)

Artificial Intelligence

Third Edition

Addison-Wesley Publishing Company 1992

8.-Robert Hecht-Nilsen (HNC, Inc. and University of California, San Diego)

Addison-Wesley Publishing Company 1991

Neurocomputing

9.-James A. Freeman

David M. Skapura

Neural Networks Algorithms, Aplications and Programming Techniques.

---

Addison-Wesly Publishing Company  
1991

10.-Simon Haykin  
Neural Networks A Comprehensive Foundation  
Macmillan Publishing Company 1994

11.-Tarun Khanna  
Foundations of Neural Networks  
Addison-Wesley Publishing Company 1990

12.-Edited By David S. Touretzky  
Morgan Kaufmann, Publishers  
San Mateo California, 1989  
Advances in Neural Information  
Processing Systems

13.-Benjamin C. Kuo  
Sistemas Automáticos de Control  
CECSA 1986

14.-Chris H Pappas/ William H. Murray. III  
Manual de Borland C++ 4.0  
Osborne McGraw-Hill 1994

15.-Katsuhikko Ogata  
Sistemas de Control en Tiempo Discreto.  
Prentice Hall 1995

16.-Margaret A. Boden  
The philosophy of artificial Intelligence  
Oxford Reaings in philosophy  
1992

17.-Byte Boons  
James S. Albus  
Brains, Behavior & Robotics  
1981

18.-Branko sourcek  
And  
The iris group  
Neural and Intelligent Systems Integration  
Wiley Interscience

19.-Jacek M. Zurada  
Introduction to Artificial Neural Systems

---

West Publishing Company

20.-Dr. Martino M  
EXPLORING AND COMPARING BEST DIRECT METHODS FOR EFFICIENT  
TRAINING OF MLP-NETWORKS,  
T-NN Nov. 1996

21.-Edited by George Adelman  
Birkhauser  
Foreword by Francis O. Schmitt  
Boston. Basel. Stuttgart  
ENCYCLOPEDIA OF NEUROSCIENCE  
1987

22.- Benjamin B. Wolman  
International encyclopedia of psychiatry psychology psychoanalysis & neurology  
Editor  
Produced for Aesculapius Publishers, Inc.  
By Van Nostrand Reinhold Company  
1997

23.-Cesar Velez Andrade 1996  
Direc. Dr. Jose Ismael Espinosa Espinosa  
Las Redes Neuronales Artificiales Contemporaneas en Hardware.

24.-Anibal Ollero Baturone  
Control por Computadora  
Descripción interna y diseño óptimo  
Alfaomega Marcombo 1992

25.-Thomas E. Quantrille Y.A. Liu  
Artificial Intelligence in chemical engineering  
Academic Press

26.-Neural Networks Control Applications

27.-Panos E. Papamichalis  
Digital Signal Processing Applications with the TMS320 Family, Volume2.  
Editor  
Prentice Hall and Digital Signal Processin Series Texas, Instruments

28.-Youngjik Lee-Sang-Hoon  
Oh-Myung Won Kim  
An Analysis of Premature Sturation in Backpropagation  
Learning Neural Network  
Perganon Prosa USA1993

---

29.-Yingdou Han, Lincheng Xiu, Zhongong Wang, Qi Chen, Student Member IEEE,  
And Shaohua Tan, Senio Member IEEE  
IEEE TRANSACTIONS ON NEURAL NETWORKS  
VOL. 8 NO. 2 MARCH 1997  
Artificial Neural Networks Controlled Fast Valving in a Power Gewneration Plant.

30.-Edited by Chan H. Dali Published in 1994 by Chapman & Hall.  
London ISBN 0412480506  
Artificial Neural Networks for Intelligent Manufacturing.  
Yung C. Shin  
Adaptive Control in Manufacturing  
Process Monitoring and Control

31.-José R. Hilera / Victor J. Martínez  
Redes Neuronales Artificiales  
Fundamentos, modelos y aplicaciones  
Addison-Wesley iberoamericana.  
1995

32.-Eli de Gortari  
INTRODUCCIÓN A LA LÓGICA DIALÉCTICA  
Tratados y manuales  
Grijalbo