

PREDICCIÓN DEL TIPO DE CAMBIO PESO-DÓLAR UTILIZANDO REDES
NEURONALES ARTIFICIALES

LUIS ALBERTO ZAPATA GARRIDO
HUGO FABIÁN DIAZ MOJICA

FUNDACIÓN UNIVERSIDAD DEL NORTE
FACULTAD DE CIENCIAS ADMINISTRATIVAS
MAESTRÍA EN ADMINISTRACIÓN DE EMPRESAS
BARRANQUILLA
2007

TABLA DE CONTENIDO

0. INTRODUCCIÓN	7
1. FORMULACIÓN DEL PROBLEMA.....	8
1.1. ANTECEDENTES.....	8
1.2. PLANTEAMIENTO DEL PROBLEMA.....	9
1.3. JUSTIFICACIÓN	10
1.4. OBJETIVOS.....	12
1.4.1. GENERAL	12
1.4.2. ESPECÍFICOS	12
1.5. ALCANCES Y LIMITACIONES.....	13
1.5.1. ALCANCES	13
1.5.1.1. COBERTURA TEMÁTICA	13
1.5.1.2. COBERTURA TEMPORAL	13
2. REDES NEURONALES: MARCO TEÓRICO.....	14
2.1. RESEÑA HISTÓRICA.....	14
2.2. EL MODELO BIOLÓGICO	16
2.3. REDES NEURONALES ARTIFICIALES	18
2.3.1. ELEMENTOS DE UNA RED NEURONAL ARTIFICIAL	18
2.3.1.1. UNIDAD DE PROCESO	18
2.3.1.2. ESTADO DE ACTIVACIÓN.....	19
2.3.1.3. FUNCIÓN DE SALIDA O DE TRANSFERENCIA	19
2.3.1.4. CONEXIONES ENTRE NEURONAS	20
2.3.1.5. FUNCIÓN O REGLA DE ACTIVACIÓN.....	20
2.3.1.6. REGLA DE APRENDIZAJE.....	21

2.3.2.	ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL	21
2.3.3.	CARACTERÍSTICAS DE LAS REDES NEURONALES.....	22
2.3.3.1.	TOPOLOGÍA	22
2.3.3.2.	MECANISMO DE APRENDIZAJE.....	23
2.3.3.2.1.	REDES CON APRENDIZAJE SUPERVISADO	24
2.3.3.2.2.	REDES CON APRENDIZAJE NO SUPERVISADO.....	25
2.3.3.3.	ASOCIACIÓN ENTRE INFORMACIÓN DE ENTRADA Y SALIDA ..	27
2.3.3.4.	REPRESENTACIÓN INFORMACIÓN DE ENTRADA Y SALIDA	28
2.3.4.	IMPLEMENTACIÓN DE LAS REDES NEURONALES	28
2.3.5.	VENTAJAS DE LAS REDES NEURONALES.....	31
2.3.6.	APLICACIONES DE LAS REDES NEURONALES.....	34
3.	SISTEMAS CAMBIARIOS: MARCO TEÓRICO.....	48
3.1.	DEFINICIÓN TIPO DE CAMBIO	48
3.1.1.	MERCADO AL CONTADO.....	49
3.1.2.	MERCADO A FUTURO	50
3.2.	MODELOS CAMBIARIOS	51
3.2.1.	TIPOS DE CAMBIO FIJOS.....	52
3.2.2.	MODELOS DE FLEXIBILIDAD LIMITADA.....	52
3.2.3.	MODELOS DE FLEXIBILIDAD.....	52
3.2.4.	MERCADOS NEGROS	53
3.3.	FUNCIÓN DE LOS BANCOS CENTRALES	54
3.4.	DETERMINACIÓN DE LOS TIPO DE CAMBIO.....	56
3.4.1.	PARIDAD DEL PODER DE COMPRA.....	57
3.4.2.	TEORÍA DE PARIDAD DE TASAS DE INTERÉS	60
3.4.3.	OTROS FACTORES	62

3.5.	PRONÓSTICO DE MOVIMIENTOS DE TIPO DE CAMBIO	63
3.5.1.	PRONÓSTICO FUNDAMENTAL Y TÉCNICO	64
3.5.2.	FACTORES POR OBSERVAR.....	66
4.	APLICACIÓN DE REDES NEURONALES PARA LA ESTIMACIÓN DEL COMPORTAMIENTO DE SISTEMAS CAMBIARIOS: ESTADO DEL ARTE	68
5.	METODOLOGÍA PROPUESTA	70
6.	REDES NEURONALES ARTIFICIALES: IMPLEMENTACIÓN	71
6.1.	RELACIÓN ENTRE LOS RESULTADOS OBTENIDOS Y LOS TIPOS DE CAMBIO VIGENTES	75
6.2.	RED NEURONAL ARTIFICIAL QUE MÁS SE ADAPTA A LA PREDICCIÓN..	76
6.3.	COMPORTAMIENTO DE LAS VARIABLES DE LA RED NEURONAL ARTIFICIAL	79
7.	CONCLUSIONES	83
8.	BIBLIOGRAFÍA.....	84
	APÉNDICE A.- RESULTADOS OBTENIDOS	85
	APÉNDICE B.- IMPORTANCIA DE CADA VARIABLE DE ENTRADA	98
	APÉNDICE C.- SENSIBILIDAD DE CADA VARIABLE DE ENTRADA.....	105
	APÉNDICE D.- VARIABLES DE LA RED NEURONAL ARTIFICIAL	113

ÍNDICE DE TABLAS

Tabla 1. Variables de entrada utilizadas.	73
Tabla 2. Datos utilizados para la predicción.	74
Tabla 3. Diferencias entre los tipos de cambio vigentes y los tipos de cambio pronosticados.	76
Tabla 4. Pesos entre las neuronas de la Prueba 1.	78
Tabla 5. Número de Neuronas en cada Red Neuronal Artificial de Prueba.	80
Tabla 6. Pesos de las Neuronas de cada Prueba.	82

ÍNDICE DE FIGURAS

Figura 1. Red neuronal biológica	17
Figura 2. Red neuronal artificial.....	22
Figura 3. Red Alimentada hacia adelante o "Feedforward"	37
Figura 4. Red con interconexión total.....	38
Figura 5. Red neuronal artificial alimentada hacia delante, con r entradas, una única capa oculta, compuesta de q elementos de proceso, y una unidad de salida.....	40

0. INTRODUCCIÓN

El presente trabajo se enfoca hacia la predicción del tipo de cambio peso-dólar a partir de la implementación de Redes Neuronales Artificiales.

Para el desarrollo de esta investigación se exploran diferentes modelos de Redes Neuronales Artificiales, las principales variables económicas relacionadas con el tipo de cambio y combinaciones de estas variables, utilizando un software especializado para realizar varias pruebas. Finalmente, se selecciona el modelo que más se adapta a la predicción teniendo en cuenta la prueba que menor margen de error arroje.

La visión del trabajo se encuentra enmarcada de la siguiente manera: en capítulo 1 se realiza la Formulación del Problema y se determinan los objetivos de la investigación. En los capítulos 2 y 3 se presenta el marco teórico de las Redes Neuronales Artificiales y de los Sistemas Cambiarios, respectivamente. El capítulo 4 corresponde al Estado del Arte de la aplicación de Redes Neuronales para la estimación del comportamiento de Sistemas Cambiarios. En el capítulo 5 se indica la metodología que se va a seguir para realizar la investigación. Y por último, en el capítulo 6 se realiza el desarrollo de los objetivos de la investigación haciendo un análisis de los resultados obtenidos.

1. FORMULACIÓN DEL PROBLEMA

1.1. ANTECEDENTES

La predicción de las cotizaciones del tipo de cambio de una divisa con respecto a otra es un tema de mucha importancia para la economía mundial, tanto por la gran cantidad de actores que participan en el mercado cambiario a nivel mundial como por los volúmenes de dinero negociados diariamente. Dentro de los principales participantes del mercado cambiario que podemos identificar son: los bancos centrales, los exportadores, los importadores, los especuladores y los inversionistas, encontrando que cada uno de estos tienen distintos intereses frente al comportamiento del tipo de cambio.

De igual forma, para muchas empresas conocer los tipos de cambio futuros de las divisas les permitiría tomar decisiones de todo tipo de inversiones y poder obtener resultados económicos con un mayor grado de certeza, con lo cual podrían reducir sus costos de manera sustancial.

Es importante tener en cuenta que existen varios factores que pueden provocar alteraciones en los tipos de cambio, entre los que encontramos los factores políticos y económicos en mayor grado. Pero incluso sucesos como la publicación de estadísticas económicas nacionales, demandas estacionales de una moneda y el fortalecimiento de una moneda tras un prolongado período de debilidad o viceversa, pueden provocar cambios en los tipos de cambio.

1.2. PLANTEAMIENTO DEL PROBLEMA

- ◆ ¿Qué tipo de Red Neuronal Artificial se adapta más a la predicción de tipos de cambio?
- ◆ ¿Cómo es el comportamiento de las variables de la Red Neuronal Artificial en el proceso de predicción de tipos de cambio?
- ◆ ¿Qué relación existe entre los resultados obtenidos y los tipos de cambio vigentes en las fechas de estudio?

1.3. JUSTIFICACIÓN

En los últimos años, las alternativas de inversión a nivel mundial han ido evolucionando y creciendo de manera exponencial, lo cual ha hecho que el comportamiento de los mercados mundiales sea muy dinámico y difícil de predecir.

La economía colombiana (sector real y sector financiero) también ha estado participando de esta dinámica mundial, lo cual se ve reflejado en las inversiones que han realizado los sectores económicos colombianos en el exterior y las inversiones extranjeras que se han hecho en el país en los últimos años.

Debido al volumen de dinero y a la gran cantidad de transacciones que realizan a diario las empresas en el contexto mundial, resulta muy importante poder predecir de manera fácil cuál va a ser el tipo de cambio futuro de la divisa en la cual negocian, ya que de esta manera pueden tener controlada su exposición cambiaria y pueden tener un mayor grado de certeza de la rentabilidad de sus inversiones en moneda extranjera.

De igual forma, conocer el tipo de cambio futuro no solo puede ser útil para que los inversionistas puedan determinar sus inversiones en monedas extranjeras, sino que también pueden determinar las inversiones que tengan correlación negativa con el comportamiento del tipo de cambio, y así poder minimizar el riesgo de su portafolio.

Debido a lo anteriormente expuesto, buscamos considerar a las redes Neuronales Artificiales (RNA) como una herramienta que sirva para predecir el tipo de cambio peso-dólar, ya que es una herramienta novedosa y de gran aplicabilidad en el sector financiero.

1.4. OBJETIVOS

1.4.1. GENERAL

- ◆ Realizar predicciones del tipo de cambio peso-dólar (COP / USD) utilizando Redes Neuronales Artificiales.

1.4.2. ESPECÍFICOS

- ◆ Determinar la relación existente entre los resultados obtenidos y los tipos de cambio vigentes en las fechas de estudio.
- ◆ Determinar el tipo de Red Neuronal Artificial que más se adapta a la predicción de tipos de cambio.
- ◆ Analizar el comportamiento de las variables de la Red Neuronal Artificial en el proceso de predicción de tipos de cambio.

1.5. ALCANCES Y LIMITACIONES

1.5.1. ALCANCES

1.5.1.1. COBERTURA TEMÁTICA

La investigación está centrada en la predicción del tipo de cambio peso-dólar (COP / USD) aplicando el concepto de las Redes Neuronales Artificiales (RNA).

1.5.1.2. COBERTURA TEMPORAL

El tiempo que cubre la información objeto de la investigación está enmarcado en el año 2006.

2. REDES NEURONALES: MARCO TEÓRICO

2.1. RESEÑA HISTÓRICA

Para iniciar, comenzaremos con el estudio de las Redes Neuronales Artificiales, para lo cual estudiaremos los planteamientos de Sandra Daza ¹ y de Maria Bonilla, Paulina Marco e Ignacio Olmeda ² y sobre el tema.

Para Sandra Daza, la historia de las Redes Neuronales Artificiales comienza a partir de la necesidad de conseguir, diseñar y construir máquinas capaces de realizar procesos con cierta inteligencia, lo cual ha sido uno de los principales objetivos y preocupaciones de los científicos a lo largo de la historia.

Las primeras explicaciones teóricas sobre el cerebro y el pensamiento fueron dadas por algunos filósofos griegos, como Platón y Aristóteles, quienes fueron apoyados después por Descartes y otros filósofos empiristas.

En 1936, Alan Turing fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación, pero quienes primero concibieron algunos fundamentos de la computación neuronal fueron Warren McCulloch y Walter Pitts (después otras teorías iniciales fueron expuestas por Donald Hebb), pero solo

¹ Sandra Patricia Daza P. Redes Neuronales Artificiales, fundamentos, modelos y aplicaciones. Universidad Militar Nueva Granada. Bogotá.

² Maria Bonilla, Paulina Marco e Ignacio Olmeda. Redes Neuronales Artificiales: Predicción de la volatilidad del tipo de cambio de la peseta. Instituto Valenciano de Investigaciones Económicas. 2002.

hasta 1957 Frank Rosenblatt comenzó el desarrollo del Perceptrón, la red neuronal más antigua.

Años más tarde, apareció el modelo ADALINE, desarrollado por Bernard Widrow y Marcial Hoff.

Stephen Grossberg realizó Avalancha en 1967 y hasta 1982 el crecimiento se frenó pero surgieron luego investigaciones sobre redes como la de Marvin Minsky y Seymour Papert, después James Anderson desarrolló el Asociador Lineal, en Japón Kunihiko Fukushima y Teuvo Kohonen que se centraron en redes neuronales para el reconocimiento de patrones; en Estados Unidos John Hopfield también realizó importantes investigaciones.

Desde 1985 comenzaron a consolidarse los congresos más importantes como Neuronal Networks for Computing y la Neural Information Processing Systems, entre algunas otras.

Actualmente, son numerosos los trabajos que se realizan y publican. Revistas como Neural Networks, Transactions on Neural Networks, entre otros, son las encargadas de la publicación de los últimos avances.

El Departamento de Defensa de los Estados Unidos y la Sociedad Europea de Redes Neuronales son algunos de los ejemplos del resurgir de la investigación sobre redes neuronales.

2.2. EL MODELO BIOLÓGICO

La teoría y modelado de redes neuronales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental.

En general, una neurona consta de un cuerpo celular más o menos esférico, de cinco (5) a diez (10) micras de diámetro, del que salen una rama principal, el axón, y varias ramas más cortas, llamadas dendritas.

Una de las características de las neuronas es su capacidad de comunicarse. En términos generales las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transmite dichas señales a los terminales axónicos, que distribuyen información a un nuevo conjunto de neuronas; se calcula que en el cerebro humano existen del orden de 10^{15} conexiones.




Figura 1. Red neuronal biológica

Las señales que se utilizan son de dos tipos: eléctrica y química. La señal generada por la neurona y transportada a lo largo del axón es un impulso eléctrico, mientras que la señal que se transmite entre los terminales axónicos de una neurona y las dendritas de la otra es de origen químico.

Para establecer una similitud directa entre la actividad sináptica y la analogía con las redes neuronales artificiales podemos realizar las siguientes consideraciones: Las señales que llegan a la sinapsis son las entradas a la neurona; estas son ponderadas (atenuadas o simplificadas) a través de un parámetro, denominado peso asociado a la sinapsis correspondiente. Estas señales de entrada pueden excitar a la neurona (sinapsis con peso positivo) o inhibirla (peso negativo). El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces la neurona se activa (da salida). Esta es una situación de todo o nada; cada neurona se activa o no se activa. La facilidad de transmisión de señales se altera mediante la actividad del sistema nervioso. Las

sinapsis son susceptibles a la fatiga, deficiencia de oxígeno y la presencia de anestésicos, entre otros. Esta habilidad de ajustar señales es un mecanismo de aprendizaje.

2.3. REDES NEURONALES ARTIFICIALES

2.3.1. ELEMENTOS DE UNA RED NEURONAL ARTIFICIAL

Las redes neuronales artificiales (RNA) son modelos que intentan reproducir el comportamiento del cerebro. Como tal modelo, realiza una simplificación, averiguando cuáles son los elementos relevantes del sistema, bien sea porque la cantidad de información de que se dispone es excesiva o bien porque es redundante. Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar determinada tarea.

2.3.1.1. UNIDAD DE PROCESO

Existen tres tipos de unidades en cualquier sistema: entradas, salidas y ocultas. Las unidades de entrada reciben señales desde el entorno; las de salida envían la señal fuera de la red, y las unidades ocultas son aquellas cuyas entradas y salidas se encuentran dentro del sistema. Se conoce como capa o nivel a un conjunto de

neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino.

2.3.1.2. ESTADO DE ACTIVACIÓN

Los estados del sistema en un tiempo t se representan por un vector $A(t)$. Los valores de activación pueden ser continuos o discretos, limitados o ilimitados. Si son discretos, suelen tomar un conjunto discreto de valores binarios, así un estado activo se indicaría con el número uno (1) y un estado pasivo estaría representado por el número cero (0). En otros modelos se considera un conjunto de estados de activación, en cuyo valor entre $[0,1]$, o en el intervalo $[-1,1]$, siendo una función sigmoideal.

2.3.1.3. FUNCIÓN DE SALIDA O DE TRANSFERENCIA

Asociada con cada unidad hay una función de salida, que transforma el estado actual de activación en una señal de salida. Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

- ◆ Función Escalón
- ◆ Función Lineal y Mixta
- ◆ Sigmoidal
- ◆ Función Gaussiana

2.3.1.4. CONEXIONES ENTRE NEURONAS

Las conexiones que unen a las neuronas que forman una RNA tiene asociado un peso, que es el que hace que la red adquiera conocimiento. Se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas y es lo que se conoce como red de propagación. Se utiliza una matriz W con todos los pesos, si W_{ji} es positivo indica que la relación entre las neuronas es excitadora, es decir, siempre que la neurona i esté activada, la neurona j recibirá una señal que tenderá a activarla. Si por el contrario W_{ji} es negativo, la sinapsis será inhibitoria. En este caso si i está activada, enviará una señal que desactivará a j . Finalmente si W_{ji} es 0 se supone que no hay conexión entre ambas

2.3.1.5. FUNCIÓN O REGLA DE ACTIVACIÓN

Se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado que existía y la combinación de las entradas con los pesos de las conexiones. Esa F es denominada función de activación, y las salidas que se obtienen en una neurona para las diferentes formas de F serán:

- ◆ Función de Activación Escalón
- ◆ Función de Activación Identidad

- ◆ Función de Activación Lineal -Mixta
- ◆ Función de Activación Sigmoidal

2.3.1.6. REGLA DE APRENDIZAJE

El aprendizaje puede ser comprendido como la modificación de comportamiento inducido por la interacción con el entorno y como resultado de experiencias, que conduce al establecimiento de nuevos modelos de respuesta a estímulos externos. En el cerebro humano el conocimiento se encuentra en la sinapsis. En el caso de las RNA el conocimiento se encuentra en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

2.3.2. ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL

Como se había mencionado anteriormente, la distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas, y existen capas de entrada, de salida, y ocultas, ahora veamos las formas de conexión entre neuronas.




Figura 2. Red neuronal artificial

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de propagación hacia adelante. Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de propagación hacia atrás.

2.3.3. CARACTERÍSTICAS DE LAS REDES NEURONALES

Existen cuatro aspectos que caracterizan una red neuronal: su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y la forma de representación de estas informaciones.

2.3.3.1. TOPOLOGÍA

La arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas formando capas más o menos alejadas de la entrada y salida de la

red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

REDES MONOCAPA

Se establecen conexiones laterales, cruzadas o autorrecurrentes entre las neuronas que pertenecen a la única capa que constituye la red. Se utilizan en tareas relacionadas con lo que se conoce como autoasociación; por ejemplo, para generar informaciones de entrada que se presentan a la red incompletas o distorsionadas.

REDES MULTICAPA

Son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Una forma de distinguir la capa a la que pertenece la neurona, consiste en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Según el tipo de conexión, como se vio previamente, se distinguen las redes feedforward, y las redes feedforward/feedback.

2.3.3.2. MECANISMO DE APRENDIZAJE

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye

cuando su peso pasa a ser cero. Se puede afirmar que el proceso de aprendizaje ha finalizado (la red ha aprendido) cuando los valores de los pesos permanecen estables ($d_{w_{ij}} / d_t = 0$).

Un criterio para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual, o si el aprendizaje supone la desconexión de la red.

Otro criterio suele considerar dos tipos de reglas de aprendizaje: las de aprendizaje supervisado y las correspondientes a un aprendizaje no supervisado, estas reglas dan pie a una de las clasificaciones que se realizan de las RNA: Redes neuronales con aprendizaje supervisado y redes neuronales con aprendizaje no supervisado.

La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo (supervisor) que controle el aprendizaje de la red.

2.3.3.2.1. REDES CON APRENDIZAJE SUPERVISADO

El proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida se

aproxime a la deseada. Se consideran tres formas de llevar a cabo este tipo de aprendizaje:

APRENDIZAJE POR CORRECCIÓN DE ERROR

Consiste en ajustar los pesos en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, en función del error.

APRENDIZAJE POR REFUERZO

Se basa en la idea de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada. La función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito=+1 o fracaso=-1), y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades.

APRENDIZAJE ESTOCÁSTICO

Este tipo de aprendizaje consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

2.3.3.2.2. REDES CON APRENDIZAJE NO SUPERVISADO

Estas redes no requieren influencia externa para ajustar los pesos de las conexiones entre neuronas. La red no recibe ninguna información por parte del

entorno que le indique si la salida generada es o no correcta, así que existen varias posibilidades en cuanto a la interpretación de la salida de estas redes.

En algunos casos, la salida representa el grado de familiaridad o similitud entre la información que se le está presentando en la entrada y las informaciones que se le han mostrado en el pasado. En otro caso podría realizar una codificación de los datos de entrada, generando a la salida una versión codificada de la entrada, con menos bits, pero manteniendo la información relevante de los datos, o algunas redes con aprendizaje no supervisado lo que realizan es un mapeo de características, obteniéndose en las neuronas de salida una disposición geométrica que representa un mapa topográfico de las características de los datos de entrada, de tal forma que si se presentan a la red informaciones similares, siempre sean afectadas neuronas de salidas próximas entre sí, en la misma zona del mapa. En general en este tipo de aprendizaje se suelen considerar dos tipos:

APRENDIZAJE HEBBIANO

Consiste básicamente en el ajuste de los pesos de las conexiones de acuerdo con la correlación, así si las dos unidades son activas (positivas), se produce un reforzamiento de la conexión. Por el contrario cuando una es activa y la otra pasiva (negativa), se produce un debilitamiento de la conexión.

APRENDIZAJE COMPETITIVO Y COOPERATIVO

Las neuronas compiten (y cooperan) unas con otras con el fin de llevar a cabo una tarea dada. Con este tipo de aprendizaje se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida se active

(alcance su valor de respuesta máximo). Por tanto las neuronas compiten por activarse, quedando finalmente una, o una por grupo, como neurona vencedora.

2.3.3.3. ASOCIACIÓN ENTRE INFORMACIÓN DE ENTRADA Y SALIDA

Las RNA son sistemas que almacenan cierta información aprendida; esta información se registra de forma distribuida en los pesos asociados a las conexiones entre neuronas de entrada y salida. Existen dos formas primarias de realizar esa asociación de entrada/salida. Una primera sería la denominada heteroasociación, que se refiere al caso en el que la red aprende parejas de datos $[(A_1, B_1), (A_2, B_2)... (A_n, B_n)]$, de tal forma que cuando se presente cierta información de entrada A_i , deberá responder generando la correspondiente salida B_i . La segunda se conoce como autoasociación, donde la red aprende ciertas informaciones $A_1, A_2...A_n$, de tal forma que cuando se le presenta una información de entrada realizará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de la entrada. Estos dos mecanismos de asociación dan lugar a dos tipos de redes neuronales: las redes heteroasociativas y las autoasociativas. Una red heteroasociativa podría considerarse aquella que computa cierta función, que en la mayoría de los casos no podrá expresarse analíticamente, entre un conjunto de entradas y un conjunto de salidas, correspondiendo a cada posible entrada una determinada salida. Existen redes heteroasociativas con conexiones feedforward, feedforward/feedback y redes con conexiones laterales. También existen redes heteroasociativas multidimensionales y su aprendizaje puede ser supervisado o no supervisado. Por otra parte, una red

autoasociativa es una red cuya principal misión es reconstruir una determinada información de entrada que se presenta incompleta o distorsionada (le asocia el dato almacenado más parecido). Pueden implementarse con una sola capa, existen conexiones laterales o también autorrecurrentes, habitualmente son de aprendizaje no supervisado.

2.3.3.4. REPRESENTACIÓN INFORMACIÓN DE ENTRADA Y SALIDA

Las redes neuronales pueden también clasificarse en función de la forma en que se representan las informaciones de entrada y las respuestas o datos de salida. Así en un gran número de redes, tanto los datos de entrada como de salida son de naturaleza analógica, cuando esto ocurre, las funciones de activación de las neuronas serán también continuas, del tipo lineal o sigmoideal. Otras redes sólo admiten valores discretos o binarios a su entrada, generando también unas respuestas en la salida de tipo binario. En este caso, las funciones de activación de las neuronas son de tipo escalón. Existe también un tipo de redes híbridas en las que las informaciones de entrada pueden ser valores continuos, aunque las salidas de la red son discretas.

2.3.4. IMPLEMENTACIÓN DE LAS REDES NEURONALES

En la búsqueda de sistemas inteligentes en general, se ha llegado a un importante desarrollo del software, dentro de esta línea se encuentran algunos de los neurocomputadores más conocidos. Un neurocomputador es básicamente un

conjunto de procesadores conectados con cierta regularidad que operan concurrentemente. En la actualidad ya existen una serie de neurocomputadores comerciales destinados a la realización de redes neuronales. Por otro lado la realización de RNA puede llevarse a cabo por medio de uno o varios circuitos integrados específicos, para así poder obtener una estructura que se comporte lo más similar posible a como lo haría una red neuronal. Otra tecnología que podría ser apropiada en la implementación de las redes neuronales es la tecnología electro-óptica, con la ventaja de utilizar la luz como medio de transporte de la información, permitiendo la transmisión, masiva de datos.

REALIZACIÓN DE REDES NEURONALES

La realización más simple e inmediata consiste en simular la red sobre un ordenador convencional mediante un software específico. Es un procedimiento rápido, económico, e instituíble, pero su mayor desventaja radica en el hecho de que se intentan simular redes con un alto grado de paralelismo sobre máquinas que ejecuten secuencialmente las operaciones. Valores intrínsecos de las redes neuronales no pueden obtenerse de esta forma.

Otro método es la realización de redes neuronales a través de arquitecturas orientadas a la ejecución de procesos con un alto de paralelismo, tales como redes de transputers, arquitecturas sistólicas, etc. Este método es una optimización del anterior, ya que el acelera el proceso, permitiendo una respuesta en tiempo real, pero el comportamiento real de la red sigue siendo simulado por una estructura ajena a la estructura intrínseca de una red neuronal.

Una tercera aproximación radicalmente distinta es la realización de redes neuronales mediante su implementación por uno o varios circuitos integrados específicos. Son los llamados chips neuronales. Las neuronas y las conexiones se emulan con dispositivos específicos, de forma que la estructura del circuito integrado refleja la arquitectura de la red. De esta forma se consiguen realizaciones que funcionan a alta velocidad.

HERRAMIENTAS SOFTWARE DE DESARROLLO

La comercialización de productos software es la forma más extendida para simular redes neuronales, debido a las ventajas citadas anteriormente. La diferencia entre los distintos productos software radica en aspectos tales como el tipo y el número de arquitecturas de red que soporta, velocidad de procesamiento, interfaz gráfica, exportación de código C para el desarrollo automático de aplicaciones, etc.

Algunos de los productos comerciales son: ANSim (DOS), ExpertNet (DOS, Windows), Neuralesk (Windows), Neuralworks Pro II/Plus (DOS, OS/2, UNIX, VMS)

NEUROCOMPUTADORES DE PROPÓSITO ESPECIAL Y DE PROPÓSITO GENERAL

Como se dijo anteriormente un neurocomputador es básicamente un conjunto de procesadores conectados con cierta regularidad que operan concurrentemente. Los de propósito general deben ser capaces de emular un gran número de modelos de red neuronal. Los de propósito especial han sido diseñados para implementar un modelo específico de red neuronal.

IMPLEMENTACIÓN MICROELECTRÓNICA (VLSI)

En general si la red ha estado previamente simulada y su configuración de conexiones perfectamente determinada, se busca la implementación sobre un circuito de conexiones fijas. La presentación del panorama que actualmente existe en el ámbito de la implementación VLSI de redes neuronales resulta complicada por la gran cantidad de aportaciones existentes, tanto en soluciones analógicas como digitales y con la alternativa de matriz de neuronas o de sinapsis.

2.3.5. VENTAJAS DE LAS REDES NEURONALES

Debido a su constitución y a sus fundamentos, las RNA presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Estas ventajas incluyen las que se mencionan a continuación.

APRENDIZAJE ADAPTATIVO

Es una de las características más atractivas de las redes neuronales, es la capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial.

En el proceso de aprendizaje, los enlaces ponderados de las neuronas se ajustan de manera que se obtengan unos resultados específicos. Una RNA no necesita un algoritmo para resolver un problema, ya que ella puede generar su propia distribución de los pesos de los enlaces mediante el aprendizaje. También existen redes que continúan aprendiendo a lo largo de su vida, después de completado el periodo inicial de entrenamiento.

La función del diseñador es únicamente la obtención de la arquitectura apropiada. No es problema del diseñador el cómo la red aprenderá a discriminar; sin embargo, si es necesario que desarrolle un buen algoritmo de aprendizaje que proporcione la capacidad de discriminar de la red mediante un entrenamiento con patrones.

AUTOORGANIZACIÓN

Las redes neuronales usan su capacidad de aprendizaje adaptativo para organizar la información que reciben durante el aprendizaje y/o la operación. Una RNA puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje. Esta autoorganización provoca la facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente.

TOLERANCIA A FALLOS

Comparados con los sistemas computacionales tradicionales, los cuales pierden su funcionalidad en cuanto sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un pequeño número de neuronas, aunque el

comportamiento del sistema se ve influenciado, sin embargo no sufre una caída repentina. Hay dos aspectos distintos respecto a la tolerancia a fallos: primero, las redes pueden aprender a reconocer patrones con ruido, distorsionados, o incompleta. Segundo pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

La razón por la que las redes neuronales son tolerantes a fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en ese tipo de almacenamiento, a diferencia de la mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos que almacenan cada pieza de información en un estado único, localizado y direccionable.

OPERACIÓN EN TIEMPO REAL

Los computadores neuronales pueden ser realizados en paralelo, y se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

FÁCIL INSERCIÓN DENTRO DE LA TECNOLOGÍA EXISTENTE

Debido a que una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo costo, es fácil insertar RNA para aplicaciones específicas dentro de sistemas existentes (chips, por ejemplo). De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas de forma incremental, y cada paso puede ser evaluado antes de acometer un desarrollo más amplio.

2.3.6. APLICACIONES DE LAS REDES NEURONALES

Las redes neuronales son una tecnología computacional emergente que puede utilizarse en un gran número y variedad de aplicaciones, tanto como comerciales como militares.

Hay muchos tipos diferentes de redes neuronales, cada uno de los cuales tiene una aplicación particular más apropiada. Separándolas según las distintas disciplinas algunos ejemplos de sus aplicaciones son:

- ◆ Biología: Aprender más acerca del cerebro y otros sistemas, obtención de modelos de la retina.
- ◆ Empresa: Reconocimiento de caracteres escritos, identificación de candidatos para posiciones específicas, optimización de plazas y horarios en líneas de vuelo, explotación de bases de datos, evaluación de probabilidad de formaciones geológicas y petrolíferas, síntesis de voz desde texto.
- ◆ Finanzas: Previsión de la evolución de los precios, valoración del riesgo de los créditos, identificación de falsificaciones, interpretación de firmas.
- ◆ Manufacturación: Robots automatizados y sistemas de control (visión artificial y sensores de presión, temperatura, gas, etc.), control de producción en líneas de proceso, inspección de calidad, filtrado de señales.
- ◆ Medicina: analizadores del habla para la ayuda de audición de sordos profundos, diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (encefalograma, etc.).

- ◆ Monitorización en cirugía: Predicción de reacciones adversas a los medicamentos, lectoras de Rayos X, entendimiento de causa de ataques epilépticos.
- ◆ Militares: Clasificación de las señales de radar, creación de armas inteligentes, optimización del uso de recursos escasos.

De igual forma, para Maria Bonilla, Paulina Marco e Ignacio Olmeda las Redes Neuronales Artificiales tratan de emular el sistema nervioso, de forma que son capaces de reproducir algunas de las principales tareas que desarrolla el cerebro humano, al reflejar las características fundamentales de comportamiento del mismo. Lo que realmente intentan modelizar las redes neuronales es una de las estructuras fisiológicas de soporte del cerebro, la neurona y los grupos estructurados e interconectados de varias de ellas, conocidos como redes de neuronas. De este modo, construyen sistemas que presentan un cierto grado de inteligencia. No obstante, debemos insistir en el hecho de que los Sistemas Neuronales Artificiales, como cualquier otra herramienta construida por el hombre, tienen limitaciones y sólo poseen un parecido superficial con sus contrapartidas biológicas.

Bonilla, Marco y Olmeda citan a Kuan y White (1994), los cuales afirman que las redes neuronales artificiales, en relación con el procesamiento de información, heredan tres características básicas de las redes de neuronas biológicas: paralelismo masivo, respuesta no lineal de las neuronas frente a las entradas recibidas y procesamiento de información a través de múltiples capas de neuronas.

De igual forma señalan que una de las principales propiedades de este sistema es la capacidad de aprender y generalizar a partir de ejemplos reales. Es decir, la red aprende a reconocer la relación (que no deja de ser equivalente a estimar una dependencia funcional) que existe entre el conjunto de entradas proporcionadas como ejemplos y sus correspondientes salidas, de modo que, finalizado el aprendizaje, cuando a la red se le presenta una nueva entrada (aunque esté incompleta o posea algún error), en base a la relación funcional establecida en el mismo, es capaz de generalizarla ofreciendo una salida.

En consecuencia, Bonilla, Marco y Olmeda definen una red neuronal artificial como un sistema inteligente capaz, no sólo de aprender, sino también de generalizar, compuesta por un conjunto de procesadores simples altamente interconectados, denominados nodos, neuronas y unidades o elementos de proceso, los cuáles se organizan en grupos, llamados capas, que permiten la conexión con el exterior y el procesamiento de información.

Al igual que Daza, los autores distinguen tres tipos de capas:

LA CAPA DE ENTRADA

Mediante la cuál se presentan los datos a la red. Está formada por nodos de entrada que reciben la información directamente del exterior.

LAS CAPAS OCULTAS O INTERMEDIAS

Que se encargan de procesar la información, se interponen entre las capas de entrada y salida. Son las únicas que no tienen conexión con el exterior.

LA CAPA DE SALIDA

Que representa la respuesta de la red a una entrada dada, siendo esta información transferida al exterior.

La estructura de red más conocida es la que se representa en la Figura 1, que se denominada red alimentada hacia delante o "feedforward", puesto que las conexiones entre neuronas se establecen en un único sentido, en el siguiente orden: capa de entrada, capa(s) oculta(s) y capa de salida. Por ejemplo, en la figura se muestra una red con dos capas ocultas. No obstante, existen también redes retroalimentadas o "feedback", que pueden tener conexiones hacia atrás, es decir, de nodos de una capa a elementos de proceso de capas anteriores, así como redes recurrentes, que pueden poseer conexiones, tanto entre neuronas de una misma capa, como de un nodo a sí mismo. La Figura 2 ilustra un modelo de red en que coexisten los distintos tipos de conexiones que hemos comentado, es decir, hacia delante, hacia atrás y recurrentes, mostrando una interconexión total.




Figura 3. Red Alimentada hacia adelante o "Feedforward"

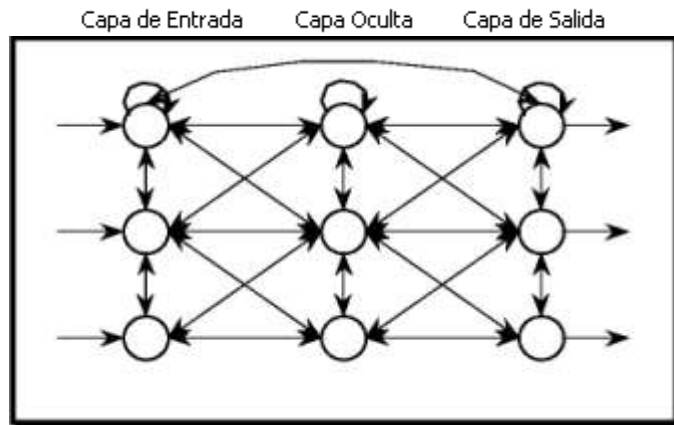


Figura 4. Red con interconexión total

Para Bonilla, Marco y Olmeda una red neuronal artificial no es más que la conexión de neuronas, que se organizan en varias capas. Las conexiones entre elementos de proceso llevan asociadas un peso o fuerza de conexión, W , que determina cuantitativamente el efecto que producen unos elementos sobre otros. Es decir, en los pesos se almacena la información de la red, al igual que sucede en las redes de neuronas biológicas. El que una entrada tenga un efecto excitatorio o inhibitorio, depende de que el signo del peso correspondiente sea, respectivamente, positivo o negativo. La efectividad de las entradas está determinada por la fuerza de la conexión, representada por el valor absoluto de los pesos. Así, cada uno de los elementos, W_{ji} de la matriz de pesos, W , conocida como patrón de conexiones, representa la intensidad y sentido de la relación del elemento de proceso j , con respecto al elemento de proceso i .

Siguiendo el planteamiento de Kuan y White (1994), Bonilla, Marco y Olmeda afirman que el proceso de transformación de las entradas en salidas, en una red neuronal artificial alimentada hacia delante, con r entradas, una única capa oculta, compuesta de q elementos de proceso, y una unidad de salida (Figura 3), puede resumirse en la siguiente formulación:

$$\hat{f}(x, W) = F\left(\beta_0 + \sum_{j=1}^q \beta_j G(x' \gamma_j)\right) \quad (1)$$

donde, $\hat{f}(x, W)$ es la salida de la red, el vector $x = (1, x_1, x_2, \dots, x_r)$ representa las entradas de la red (el 1 se corresponde con el sesgo de un modelo tradicional), $\gamma_j = (\gamma_{j0}, \gamma_{j1}, \dots, \gamma_{ji}, \dots, \gamma_{jr}) \in \mathfrak{R}^{r+1}$ son los pesos de las neuronas de la capa de entrada a las de la intermedia u oculta, $\beta_j, j = 0, \dots, q$, representa la fuerza de conexión de las unidades ocultas a las de salida ($j=0$ indexa la unidad sesgo), q es el número de unidades intermedias, es decir, el número de nodos de la capa oculta, $F: \mathfrak{R} \rightarrow \mathfrak{R}$ es la función de activación de la unidad de salida y $G: \mathfrak{R} \rightarrow \mathfrak{R}$ se corresponde con la función de activación de las neuronas intermedias. W es un vector que incluye todos los pesos de la red, es decir, γ_j y β_j .




Figura 5. Red neuronal artificial alimentada hacia delante, con r entradas, una única capa oculta, compuesta de q elementos de proceso, y una unidad de salida

La función de activación permite incorporar en los modelos de redes neuronales artificiales una de las propiedades de los sistemas biológicos que, a su vez, introduce la importante característica de respuesta no lineal en las redes de neuronas artificiales. Este fenómeno puede resumirse en la tendencia de ciertas clases de neuronas a ponerse en actividad sólo cuando el nivel de actividad de su entrada supera un umbral determinado, en caso contrario permanecen estables.

Históricamente, en principio se emplearon funciones de umbral, cuyo efecto es que las unidades se activan bruscamente, esto es, o no se activan, o se activan de golpe. La respuesta sólo puede ser "blanco o negro", por ello, estas funciones son adecuadas para tareas de clasificación y reconocimiento. Con el tiempo, se introdujeron funciones de activación que permiten que las neuronas se activen gradualmente a medida que el nivel de actividad de sus entradas aumenta, en lugar de que su estado pueda ser, únicamente, activación - desactivación. En

concreto, la función que se propone es la sigmoïdal o logística [Cowan, 1967] $G(a) = 1/(1 + \exp(-a))$, que produce una respuesta sigmoïdal alisada. Como podemos observar, si volvemos a la notación de la expresión [1] y consideramos que $ax\gamma_j$, nos encontramos con que $G(x\gamma_j)$ se corresponde con el conocido modelo logit de probabilidad binaria.

En general, las funciones F y G pueden adoptar cualquier forma. Ahora bien, es práctica habitual considerar, bien que la función de activación de las neuronas de salida y de las intermedias es idéntica, $F(a) = G(a)$ y que se corresponde con la función sigmoïdal, o bien, que $F(a) = a$, es decir, que es la función identidad y que $G(a)$ se corresponde con la función logística o sigmoïdal, lo que es equivalente a considerar que sólo existe función de activación (la sigmoïdal) en las unidades ocultas.

Suponiendo, como hemos indicado, que sólo existe función de activación en las neuronas intermedias y que ésta se corresponde con la sigmoïdal, la expresión [1] se transforma en:

$$\hat{f}(x, W) = \beta_0 + \sum_{j=1}^q \beta_j G(x\gamma_j) \quad [2]$$

Otra posibilidad, de gran utilidad en aplicaciones econométricas, es considerar que en la red que representamos, una red neuronal artificial alimentada hacia delante,

con r entradas, una única capa oculta, compuesta de q elementos de proceso, y una unidad de salida, también existen conexiones directas entre la capa de entrada y la de salida. En este caso, la salida de la red se obtiene mediante la siguiente expresión:

$$\hat{f}(x, W) = x'\alpha + \beta_0 + \sum_{j=1}^q \beta_j G(x'\gamma_j) \quad [3]$$

Donde α es un vector de dimensión $r \times 1$ que representa los pesos de las conexiones directas entre las capas de entrada y salida. Como es lógico, ahora W , que recoge la totalidad de pesos de la red, se compone de α_j y β_j .

Para interpretar la expresión [3] podemos descomponerla en dos partes. La primera de ellas, que se corresponde con los dos primeros términos, representa un modelo lineal, de manera que, si tomamos como variables de entrada r retardos de la variable x , se convierte en una regresión lineal sobre las variables de entrada retardadas, que actúan como variables explicativas, y una constante (β_0).

Es decir, en un contexto de series temporales en que $x = x_{t-1} + x_{t-2}, \dots, x_{t-r}$ puede considerarse como un modelo autorregresivo de orden r , $AR(r)$. Esta primera parte, como es lógico, capta las dependencias lineales entre los patrones de entrada y las salidas de la red. La segunda parte, que es el tercer término de la formulación anterior, recoge, en caso de que existan, las dependencias no lineales

entre las variables de entrada y la salida de la red, dado que la función empleada es no lineal. Concretando, este tercer término es una composición, ponderada con los pesos sinápticos de las neuronas intermedias a las de salida (\exists_j), de funciones sigmoideas de las entradas de la red, ponderadas, éstas últimas, por la fuerza de conexión de las unidades de entrada a las intermedias. Este modelo puede considerarse una extensión de los conocidos y, tan frecuentemente utilizados, modelos lineales, ya que se compone de un modelo lineal, aumentado con términos no lineales.

Tras diseñar una red neuronal artificial, lo que se pretende conseguir con la misma es que, para ciertas entradas, o patrones ejemplo que suministramos a la red, ésta sea capaz de generar una salida deseada. Para ello, además de que la topología de la red (entendida como la estructura de la red) sea adecuada, se requiere que la misma aprenda a proporcionar soluciones correctas, es decir, es necesario someter a la red a un proceso de aprendizaje o entrenamiento. El aprendizaje puede entenderse como un procedimiento de prueba y error que permite la estimación estadística de los parámetros del modelo de red neuronal empleado.

Generalmente, el método que emplea el algoritmo de aprendizaje para conocer el grado de adecuación de los pesos consiste en comparar la salida de la red ($\hat{f}(x_t, W)$) con la deseada (y_t), es decir, calcular el error cometido ($e_t = e(\hat{f}(x_t, W), y_t)$). De este modo, cuando se producen errores se reajustan los pesos y reinicializa el proceso, hasta lograr la estructura de pesos idónea, esto es,

la que minimiza el error de salida de la red $e_i \in \mathfrak{R}^P$ a lo largo del conjunto de ejemplos Z^n , al que normalmente nos referimos como conjunto de entrenamiento o aprendizaje.

Para definir el concepto de generalización podemos decir que una red neuronal generaliza en un sentido óptimo, si para cualquier observación seleccionada aleatoriamente que se le presente, aunque no forme parte del conjunto de entrenamiento, la salida que genera minimiza el error de salida de la red. Formalmente, el proceso del aprendizaje consiste en resolver un problema de mínimos cuadrados no lineales. Para ello, hay que emplear métodos numéricos de optimización como el de retropropagación de errores ("Backpropagation"), que surge de Werbos (1974), atribuible también a Parker (1982, 1985) y Le Cun (1985). Este método se fundamenta en el algoritmo de aproximación estocástica de Robbins y Monro (1951). Actualmente, viene siendo el algoritmo más utilizado.

El proceso de aprendizaje consiste en modificar los pesos de la red (donde se acumula la información), hasta que el patrón de conexiones, W , resulta óptimo. En este sentido, si la red aprende, el conocimiento acumulado en el momento $t+1$, W_{t+1} , debe ser mayor que el acumulado en el momento t , W_t , de manera que, $W_{t+1} = W_t + \Delta_t \cdot \Delta_t$, representa la cantidad de conocimiento aprendido por la red, o modificación de los pesos, entre los momentos t y $t+1$. Esta variación de los pesos depende, lógicamente, de los pares entrada-salida deseada que se proporcionan a la red y de los pesos de la misma, es decir $\Delta_t = \psi_i(Z_t, W_t)$. Pues bien, un algoritmo de aprendizaje, como es lógico, debe proporcionar la forma de

ir cambiando los pesos al objeto de optimizar el comportamiento de la red. El algoritmo de retropropagación de errores propone la siguiente regla, basada en el descenso del gradiente, para modificar adecuadamente los pesos:

$$W_{t+1} = W_t + \alpha \nabla \hat{f}(x_t, W_t) (Y_t - \hat{f}(x_t, W_t)) \quad [4]$$

Siendo α una constante denominada tasa de aprendizaje y $\nabla \hat{f}(x_t, W_t)$ el gradiente de la salida que genera la red en el momento t , $\hat{f}(x_t, W_t)$ en relación con los pesos en dicho instante W_t . Esta expresión muestra que el valor de un peso en un determinado momento depende del valor adoptado en el instante anterior, de la tasa de aprendizaje, del error cometido por la red en el momento anterior y de la sensibilidad del output del modelo ante las variaciones de dicho peso.

Antes de iniciarse el proceso de aprendizaje, los pesos toman valores aleatorios relativamente pequeños, para que la red no se sature con grandes pesos, y de este modo comenzar en un punto aleatorio de la superficie de error.

Una vez finalizado el aprendizaje se debe proceder a testear la red. La fase de test consiste en introducir nuevos patrones de entrada y comprobar la eficacia del sistema generado. Si no resulta aceptable se repite la fase de entrenamiento utilizando nuevos patrones-ejemplo, e incluso puede ser necesario modificar la estructura de la red.

Para finalizar, y analizada la estructura y funcionamiento de las redes neuronales, debemos puntualizar un problema que las mismas pueden presentar y que es común a todos los métodos no paramétricos, el del sobreaprendizaje o sobreajuste, que está relacionado con el tamaño o número de parámetros de la red.

Una red infradimensionada, es decir, cuyo número de parámetros es menor al que requiere el problema, nunca puede llegar a aprender la relación entre las variables entrada-salida deseada del conjunto de entrenamiento. En consecuencia, es incapaz de generalizar correctamente. Por el contrario, una red sobredimensionada memoriza el conjunto de aprendizaje y lo reproduce. Sin embargo, al no aprender la relación entre las variables de interés, es incapaz de generalizar.

En general, la mejor red, con mayor poder de generalización, es la más sencilla, siempre que su comportamiento a lo largo del conjunto de aprendizaje sea eficiente. El número de unidades que deben utilizarse en las capas de entrada y de salida suele ser bastante evidente; tantas neuronas de entrada como variables explicativas y de salida como variables a predecir. El problema reside en determinar el número de nodos de las capas ocultas. Una de las técnicas utilizadas para determinar el tamaño óptimo de la red consiste en comenzar con una red de un nodo y añadir otros cuando es necesario. La técnica opuesta empieza con una red muy grande, cuyos nodos innecesarios se eliminan paulatinamente.

De entre los métodos más conocidos para evitar el sobreaprendizaje podemos destacar: la detención prematura del aprendizaje, el establecimiento de un control estadístico del tamaño de la red, la reducción del tamaño de la red por cualquiera de los métodos posibles y el empleo de arquitecturas autogenerativas (Olmeda, 1993).

3. SISTEMAS CAMBIARIOS: MARCO TEÓRICO

3.1. DEFINICIÓN TIPO DE CAMBIO

Un tipo de cambio es el número de unidades de una moneda que se debe entregar para adquirir una unidad de otra moneda; es la relación entre monedas nacionales diferentes gracias a la cual es posible realizar comparaciones internacionales de precios y costos.

El tipo de cambio al contado (spot) es la cotización que se aplica en el momento mismo en que se realizan las transacciones con monedas extranjeras. Se aplica por ejemplo a las transacciones interbancarias que suponen la entrega de la moneda adquirida a más tardar dos días hábiles después del pago en efectivo inmediato que corresponda. Este proceso de intercambio se llama liquidación. Las transacciones interbancarias son los intercambios entre bancos comerciales, cuyo conjunto compone el mercado interbancario, el mercado de las operaciones que tienen lugar entre esos bancos. El tipo de cambio al contado también se aplica a las transacciones al contado informales (o "sobre el mostrador", por la expresión inglesa *over-the-counter*, OTC), en las que, por lo general, participan clientes distintos a las entidades bancarias y que requieren de liquidación el mismo día. El tipo de cambio a futuro es un tipo de cambio contractual entre un agente de divisas y un cliente para la entrega de una moneda extranjera en el futuro, después de al menos dos días hábiles, aunque por lo general después de cuando menos un mes.

3.1.1. MERCADO AL CONTADO

La mayoría de las transacciones de monedas extranjeras ocurren entre agentes de divisas, de manera que son estos (quienes trabajan para casas de intermediación cambiaria o bancos comerciales) quienes cotizan los tipos de cambio. Los tipos de cambio los cotizan los agentes, no la parte compradora o vendedora. Los agentes siempre cotizan un tipo de cambio de demanda (de compra) y uno de oferta (de venta). El tipo de cambio de demanda es el precio al cual el agente está dispuesto a comprar monedas extranjeras, y de oferta es el precio al cual el agente está dispuesto a vender monedas extranjeras. En el mercado al contado, el diferencial es la diferencia entre los tipos de cambio de demanda y oferta, y por lo tanto el margen de ganancia del agente en la transacción. Es obvio que todo agente desea comprar barato y vender caro.

La cotización de un tipo de cambio en términos del número de unidades de la moneda extranjera por una unidad de la moneda nacional se llama cotización indirecta, lo contrario de la cotización directa.

El dólar estadounidense sirve como base para transacciones internacionales; la otra moneda presente en la transacción es la cotizada. La moneda base ocupa el lugar denominador en la cotización; la moneda cotizada, el del numerador. La cotización se expresa como el número de unidades de la moneda cotizada por una unidad de la moneda base.

Una última definición importante que se aplica al mercado al contado es la de tipo de cambio cruzado. Este tipo de cambio se calcula a partir de otros dos tipos de cambio. Dado que la mayoría de las transacciones de monedas extranjeras se denominan en dólares estadounidenses, es común que se establezca una relación entre dos monedas diferentes al dólar por medio de un tipo de cambio cruzado.

3.1.2. MERCADO A FUTURO

El mercado a contado es para transacciones de divisas con una duración máxima de dos días hábiles. Sin embargo, algunas transacciones pueden iniciarse un día pero no consumarse hasta después de dos días hábiles.

Así, el tipo de cambio futuro es la cotización del tipo de cambio fijada por agentes de divisas para la compra o venta de divisas en el futuro. La diferencia entre los tipos de cambio al contado y a futuro se llama ya sea descuento a futuro o prima a futuro del contrato. Si la moneda nacional se cotiza directamente y el tipo de cambio a futuro es menor que el tipo de cambio al contado, la moneda extranjera se vende con descuento. Si el tipo a futuro es mayor que el tipo contado, la moneda extranjera se vende con prima.

3.2. MODELOS CAMBIARIOS

En el Acuerdo de Jamaica se formalizó el abandono de los tipos de cambio fijos. Como parte de esta decisión, el Fondo Monetario Internacional (FMI) permitió a los países elegir y mantener el modelo cambiario de su preferencia, no sin antes hacerlo del conocimiento del Fondo. Cada año, los países informan al FMI acerca del modelo cambiario que emplearán, el cual ha de corresponder a una de las tres grandes categorías siguientes:

TIPOS DE CAMBIO FIJOS

Monedas que fijan su valor en relación con una sola moneda o un conjunto de monedas.

MODELOS DE FLEXIBILIDAD LIMITADA

Tipos de cambio con flexibilidad limitada en relación con una sola o un grupo de monedas

MODELOS FLEXIBLES

Tipos de cambio muy flexibles (categoría que incluye a monedas flotantes como el renmibi chino).

Es importante que las empresas multinacionales conozcan los modelos cambiarios de la moneda de los países en los que realizan operaciones de negocios para que puedan elaborar pronósticos de tendencias más precisos. Resulta mucho más sencillo pronosticar el futuro tipo de cambio de una moneda relativamente estable

fijada en correspondencia con el dólar estadounidense, como el peso argentino, que una moneda de libre flotación, como el yen japonés.

3.2.1. TIPOS DE CAMBIO FIJOS

Los países que aplican esta categoría de modelos cambiarios fijan el valor de su moneda al de otra o al de un grupo de monedas, con márgenes muy estrechos, de uno por ciento o menos. Algunos países de la última subcategoría han seleccionado una canasta de monedas diferente a la de los Derechos Especiales de Giro (DEG).

3.2.2. MODELOS DE FLEXIBILIDAD LIMITADA

La categoría de modelos cambiarios de flexibilidad limitada se divide en dos subcategorías. Los tipos de cambio pertenecientes a la primera, "flexibilidad limitada en términos de una sola moneda", fluctúan en un margen de 2.25 por ciento; y la segunda es "flexibilidad limitada por un acuerdo de cooperación".

3.2.3. MODELOS DE FLEXIBILIDAD

Las monedas de los países que adoptan modelos flexibles flotan de manera independiente, aunque el gobierno interviene para influir en, más no para neutralizar, la velocidad de modificación del tipo de cambio. Los dirigentes de los principales países industriales de esta categoría se reúnen periódicamente para

discutir asuntos económicos comunes; con frecuencia uno de los temas de sus conversaciones es el valor de los tipos de cambio.

3.2.4. MERCADOS NEGROS

En muchos países existe un mercado negro aparte del mercado oficial, mas apegado a las fuerzas de la oferta y la demanda que este último. Cuanto menos flexible sea el modelo cambiario de un país, es más probable la existencia en él de un mercado negro. El mercado negro es producto del hecho de que la gente piense que el gobierno compra dólares a un valor inferior a su valor real. De acuerdo con la teoría económica, si el tipo de cambio oficial del gobierno está sobrevaluado, el mercado negro tenderá a subvalorarlo. Es probable que el verdadero valor económico de la moneda en cuestión corresponda a un punto intermedio.

El mercado negro es problemático para las compañías, ya que proporciona una medida más precisa del valor de una moneda que el mercado oficial. Esto es de particular importancia en la información financiera.

3.3. FUNCIÓN DE LOS BANCOS CENTRALES

Cada país dispone de un banco central responsable de las políticas relativas al valor de su moneda en los mercados mundiales. Los bancos centrales mantienen sus activos bajo dos formas (reservas en oro y en divisas), aunque también pueden hacerlo en DEG y en la posición de reserva de su país en el FMI. La medida del oro es difícil, porque los gobiernos valúan oficialmente sus reservas de oro en 35 dólares la onza (28.35 gramos), mientras que el precio de mercado de este metal es más de 10 veces superior. Como resultado de ellos, el FMI da a conocer no solo la valuación nacional de oro al precio oficial de 35 dólares la onza, sino también los millones de onzas de oro contenidos en las reservas, para que se pueda calcular su valor de mercado. En 1996, 91.9 por ciento de las reservas totales del mundo entero eran reservas de divisas. Aun así, la proporción de los principales activos de reserva varía de un país a otro.

En razón de que la mayoría de los bancos centrales consideran al oro como su activo de reserva más importante, sus haberes se mantienen sumamente constantes. Uno de los intereses primordiales de los bancos centrales es la liquidez, con la que garantizan el efectivo y la flexibilidad que necesitan para proteger la moneda del país. La combinación de divisas de las reservas de un país se basa en sus principales monedas de intervención, la divisas con las que mas opera. El grado en el que un banco central administra activamente sus reservas para obtener ganancias varía según el país de que se trate. En general, los bancos asiáticos, y en especial el Banco Central de Malasia, son más ambiciosos que los

Europeos y el Sistema de la Reserva Federal estadounidense en la generación de ganancias con base en las reservas.³

Así mismo, las políticas gubernamentales cambian en el transcurso del tiempo, dependiendo del gobierno en particular en el poder. En los primeros dos años y medio del primer periodo presidencial de William Clinton en Estados Unidos, El Departamento del Tesoro estadounidense intervino en el mercado mediante la compra de dólares solo en 18 días, lo que le significó egresos por alrededor de 12.500 millones de dólares, mientras que, en lo que toca sólo a 1989, el Departamento del Tesoro, bajo el gobierno de George Bush, compró y vendió dólares en 97 de los 260 días hábiles de ese año, habiendo ascendido sus ventas a 19.500 millones de dólares. Las diferencias en cuanto a la intervención responden a diferencias de filosofía. La intensa intervención del gobierno Bush se debió a su intención de mantener el dólar en un nivel cambiario flexible en momentos en los que el valor de este frente al marco y al yen se elevaba. El gobierno de Clinton, por el contrario, fue mucho más selectivo en sus intervenciones; el mercado era tomado por sorpresa y después se le daba gran difusión a la intervención. Una intervención menos frecuente y más sutil demostró ser más eficaz, así como más acorde con la filosofía de la Junta de la Reserva Federal.

³ Fondo Monetario Internacional. International Financial Statistics (Washington D.C.: IMF, Febrero 1997).

3.4. DETERMINACIÓN DE LOS TIPO DE CAMBIO

Los tipos de cambio se determinan de acuerdo con una de las tres clases principales de sistemas cambiarios: de libre fluctuación, de tipo de cambio fijo controlado y de tipo de cambio fijo automático. Los factores que afectan a los tipos de cambio son la inflación, los diferenciales de las tasas de interés y los factores técnicos.

MONEDAS DE LIBRE FLUCTUACIÓN

Las monedas que fluctúan libremente responden a las condiciones de oferta y demanda con relativa independencia de la intervención gubernamental.

SISTEMAS DE TIPO DE CAMBIO FIJO CONTROLADO

En este caso los gobiernos compran y venden sus divisas en el mercado abierto, como método para influir en el precio de dichas divisas.

SISTEMAS DE TIPO DE CAMBIO FIJO AUTOMÁTICO

Este sistema se diferencia de los demás en que el ajuste de los tipos de cambio no dependen de la intervención gubernamental, si no de la alteración de la oferta interna de dinero. La modificación del tipo de cambio de una moneda en libre fluctuación está en función en mayor medida de la oferta y demanda de aquella en el mercado de divisas que el mercado interno. Así, aunque la ley de oferta y la demanda puede determinar los tipos de cambio en un mercado abierto, muchos gobiernos intervienen en el mercado para influir en los movimientos del tipo de cambio. La aplicación del sistema de tipo de cambio fijo automático es factible,

pero se le usa menos que los sistemas de monedas de libre fluctuación y de tipo de cambio fijo controlado.

3.4.1. PARIDAD DEL PODER DE COMPRA

La paridad del poder de compra (PPC) es la teoría clave que explica las relaciones entre las monedas. En esencia, sostiene que una variación en la inflación relativa debe resultar en una variación en los tipos de cambio para mantener los precios de los bienes de los dos países en un nivel similar. De acuerdo con la teoría de la PPC, si, por ejemplo, la inflación en Japón fuera de 2% y en Estados Unidos de 3.5%, sería de esperar que el dólar descendiera en la misma proporción representado por la diferencia entre las tasas de inflación. En consecuencia, el dólar equivaldría a menos yenes que antes del ajuste y el yen valdría más dólares que antes del ajuste.

La siguiente fórmula sirve para relacionar la inflación con modificaciones en los tipos de cambio:

$$\frac{e_t - e_0}{e_0} = \frac{i_{h,t} - i_{f,t}}{1 + i_{f,t}} \quad (5)$$

Donde:

e : El tipo de cambio cotizado en términos del número de unidades de la moneda nacional por una unidad de la moneda extranjera.

i : Tasa de inflación

h : Indica el país nativo (home country en inglés)

f : Indica el país extranjero (foreign country en inglés)

0 : Indica el inicio del periodo

t : Indica el fin del periodo

El tipo de cambio futuro previsto está dado por:

$$e_t = e_0 \left(\frac{1 + i_{h,t}}{1 + i_{f,t}} \right) \quad (6)$$

Un ejemplo interesante de la falibilidad de la teoría de la PPC en la estimación de tipo de cambio es el representado por el índice de monedas basado en la Big Mac que cada año publica la revista The Economist. El precio de una hamburguesa Big Mac puede servir para estimar el tipo de cambio entre el dólar y otra moneda. Por ejemplo, en 1996 una Big Mac tenía un costo promedio en Estados Unidos de 2.36 dólares y en Japón de 288 yenes. Si se divide el precio en yenes entre el precio en dólares, se obtiene como resultado un tipo de cambio de 122 yenes por dólar, de acuerdo con la teoría de la PPC. Sin embargo, el tipo de cambio vigente era de 107 yenes por dólar, de manera que el yen estaba sobrevaluado en comparación con el dólar. En otras palabras, se necesitarían más dólares para comprar una Big Mac en Japón que en estados Unidos. Con base en el tipo de cambio vigente, una Big Mac habría costado entonces 2.70 dólares en Japón en lugar de 2.36. La sobrevaluación del yen volvió mas costosas las compras de los turistas estadounidenses en Japón, pero para los turistas japoneses convirtió una ganga viajar a Estados Unidos. El índice basado en la Big Mac, también conocido como

“Mc Parity”, tiene defensores lo mismo que detractores. La Mc Parity quizá sea sostenible a largo plazo, como se ha demostrado en algunos estudios, mientras que la PPC se ve afectada por problemas de corto plazo:

- ◆ La teoría de la PPC parte del falso supuesto de que no existen barreras al comercio y de que los costos de transporte son cero.
- ◆ Los precios de la Big Mac en diferentes países sufren los efectos distorsionantes de los impuestos. El precio en los países europeos con elevados impuestos al valor agregado tal vez es mayor que el de países con bajos impuestos.
- ◆ La Big Mac no se reduce a una canasta de mercancías; su precio también incluye costos no estrictamente comerciales, como renta, seguros, etc.
- ◆ Los márgenes de utilidad varían de acuerdo con la intensidad de la competencia. Cuanto mayor sea la competencia, menos será el margen de utilidad, y por lo tanto el precio.

Así pues, el precio relativo de los bienes está sujeto a alteraciones por efecto de modificaciones al tipo de cambio y al precio interno.

3.4.2. TEORÍA DE PARIDAD DE TASAS DE INTERÉS

Si bien la inflación es el factor con mayor influencia a largo plazo en los tipos de cambio, también las tasas de interés son importantes. Por ejemplo, en un artículo sobre el mercado de divisas publicado en el Wall Street Journal se hacía notar de esta manera el impacto de las tasa de interés en los tipos de cambio:

*"Los operadores de divisas se apresuraron a comprar marcos el martes pasado luego de que ciertos indicios en los comentarios de funcionarios económicos y monetarios alemanes proyectaron dudas sobre el futuro de la prevista moneda única europea. Además, funcionarios del Bundesbank (banco central alemán) informaron que éste no reducirá en lo inmediato las tasas de interés vigentes en Alemania. Esta noticia provocó que las compras de marcos con base en dólares se intensificaran aún más (...). La situación respecto del yen fue distinta. Previendo que las tasas de interés japonesas no aumentarán pronto, los operadores empujaron el dólar al alza (...). Dada la expectativa de que las tasas de interés de Japón se mantengan en un bajo nivel y la probabilidad de que Estados Unidos persista en su política en favor de la fortaleza del dólar, cabe suponer que, a causa del bajo rendimiento del yen, los inversionistas venderán yenes a cambio de casi cualquier otra moneda."*⁴

Para comprender este fenómeno, es preciso conocer dos importantes teorías financieras: el efecto de Fisher y el efecto internacional de Fisher. En la primera se

⁴ Betty W. Liu. "Traders Line Up For Marks as Germans Cast Doubts on Single-Currency Plan", Wall Street Journal, Octubre 30, 1996, p. C26.

establece una relación entre la inflación y las tasas de interés, mientras que en la segunda las tasas de interés se vinculan con los tipos de cambio. El efecto de Fisher es la teoría de que la tasa de interés nominal r de un país está determinada por la tasa de interés real R y la tasa de inflación i de la siguiente manera:

$$(1+r) = (1+R)(1+i) \quad (7)$$

De acuerdo con esta teoría, si la tasa de interés real es de 5%, la tasa de inflación estadounidense de 2.9% y la tasa de inflación japonesa de 1.5%, entonces las tasas de interés nominales de Estados Unidos y Japón se calculan de esta forma:

$$R_{eu} = (1.05)(1.029) - 1 = 0.08045, 8.045\%$$

$$R_j = (1.05)(1.015) - 1 = 0.06575, 6.575\%$$

Así, la diferencia entre las tasas de interés estadounidense y japonesa está en función de la diferencia entre sus tasas de inflación. Si sus tasas de inflación fueran iguales (diferencial de cero), pero la tasa de interés de Estados Unidos fuera de 10% y la de Japón de 6.575%, los inversionistas colocarían su dinero en Estados Unidos, donde podrían obtener el mayor rendimiento real.

El puente entre tasas de interés y tipos de cambio puede explicarse con el efecto internacional de Fisher (EIF), la teoría de que el diferencial de la tasa de interés es un indicador imparcial de futuras modificaciones en el tipo de cambio al contado. Por ejemplo, el EIF prevé que si las tasas de interés nominales de Estados Unidos

son más altas que las de Japón, el valor del dólar deberá descender en el futuro en una proporción igual a la del diferencial de las tasas de interés, lo que indicaría un debilitamiento, o depreciación, del dólar. Esto se debe a que el diferencial de las tasas de interés se basa en las diferencias en las tasas de inflación, como se explicó anteriormente. Todos estos aspectos tienen repercusiones a largo plazo, desde luego, de manera que es probable que a corto plazo no suceda nada. En periodos de estabilidad general de precios, un país que elevara sus tasas de interés probablemente atraería capital y vería ascender el valor de su moneda a causa del incremento de la demanda. Sin embargo, si la razón del aumento de las tasas de interés es el hecho de que la tasa de inflación del país excede a las de sus principales socios comerciales y que por este medio el banco central pretende reducir la inflación, la moneda se debilitará hasta que la inflación descienda.

Aunque el diferencial de las tasas de interés es el factor decisivo de algunas de las monedas intercambiadas con mayor intensidad, la expectativa acerca del tipo de cambio al contado futuro también es muy importante. Por lo general, un operador estimará automáticamente el tipo de cambio al contado futuro con base en el diferencial de la tasa de interés, el cual ajustará después de acuerdo con otras condiciones del mercado.

3.4.3. OTROS FACTORES

Varios otros factores pueden provocar alteraciones en los tipos de cambio. Una de las determinantes más importantes, por efecto de la incertidumbre política y

económica siempre reinante, es la confianza. En momentos difíciles, la gente prefiere poseer monedas consideradas seguras. Por ejemplo, durante el periodo de incertidumbre política que privó en Rusia en 1996 a causa del cada vez peor estado de salud del presidente, Boris Yeltsin, muchas personas sacaron su dinero de Alemania para trasladarlo a Estados Unidos, temerosas de la suerte que correría Europa Occidental en caso de que en Rusia se desatara una crisis.

Aparte de las fuerzas económicas básicas y de la confianza en los dirigentes, los tipos de cambio también están sujetos a la influencia de varios factores técnicos, como la publicación de estadísticas económicas nacionales, las demandas estacionales de una moneda y el ligero fortalecimiento de una moneda tras un prolongado periodo de debilidad, o viceversa.

3.5. PRONÓSTICO DE MOVIMIENTOS DE TIPO DE CAMBIO

Dado que son muchos los factores que influyen en los movimientos de los tipos de cambio, los administradores deben estar en condiciones de analizarlos para poder formular una idea general acerca del momento, magnitud y dirección de un movimiento en los tipos de cambio. Sin embargo, la predicción no es una ciencia exacta, de manera que muchas cosas pueden provocar que las mejores predicciones difieran mucho de la realidad.

3.5.1. PRONÓSTICO FUNDAMENTAL Y TÉCNICO

El pronóstico de los tipos de cambio puede realizarse con base en dos métodos distintos: el fundamental y el técnico. El pronóstico fundamental implica la utilización de las tendencias de las variables económicas para predecir los tipos futuros. Los datos pueden remitirse a un modelo económico o evaluarse más subjetivamente. El pronóstico técnico supone el uso de tendencias del pasado para trazar tendencias futuras. Los pronosticadores técnicos, también conocidos como diagramadores, parten del supuesto de que si los tipos de cambio vigentes reflejan todos los hechos presentes en mercado, los tipos de cambio futuros seguirán los mismos patrones en circunstancias similares.

Sin embargo, todo pronóstico es impreciso. El tesorero de una compañía interesado en pronosticar un tipo de cambio (como, por ejemplo, la relación entre la libra inglesa y el dólar estadounidense), podría servirse para ello de una amplia variedad de fuentes, tanto internas como externas a la compañía. Muchos tesoreros y ejecutivos bancarios recurren a analistas externos para obtener información para sus pronósticos. Los analistas deben proporcionar estimaciones generales o puntuales con probabilidades subjetivas basadas tanto en los datos disponibles como en interpretaciones subjetivas. Entre los sesgos que pueden tergiversar los pronósticos se encuentran los siguientes:

- ◆ Reacción exagerada a noticias inesperadas y dramáticas.
- ◆ Correlación ilusoria, es decir, la tendencia a percibir en los datos correlaciones o asociaciones no estadísticamente comprobadas, sino producto de nociones preconcebidas.
- ◆ Énfasis en un subconjunto particular de información a expensas del conjunto general.
- ◆ Insuficiencia de los ajustes debidos a aspectos subjetivos, como la volatilidad del mercado.
- ◆ Incapacidad para aprender de los propios errores.
- ◆ Exceso de confianza en la debilidad personal.

Los buenos tesoreros y ejecutivos bancarios elaboran pronósticos propios de lo que cederá con una moneda en particular y se sirven de los pronósticos fundamentales o técnicos de analistas externos para corroborar los suyos. Esto les permite determinar si han tomado en cuenta factores importantes y si deben revisar sus pronósticos a la luz de análisis externos. Es importante insistir en que por más meticulosamente que se elabore un pronóstico, este no deja de ser una conjetura. Pronosticar supone predecir el momento, dirección y magnitud de una variación de los tipos de cambio. El momento es a menudo una decisión política, de modo que no se trata necesariamente de un elemento racional o previsible. Y aunque quizá sea probable prever la dirección de una variación, su magnitud es difícil de pronosticar.

Por ejemplo, el pronóstico de monedas es importante para Chrysler, en virtud de sus inversiones extranjeras, oportunidades en el mercado externo y provisión de

componentes de fuentes foráneas. Esta compañía se sirve de tres modelos de pronóstico. Partiendo de la dificultad de pronosticar tipos de cambio, basa en gran medida sus pronósticos de corto plazo (de una semana a un mes) en la información cualitativa que recibe de sus administradores locales. También recurre a agentes de divisas externos especializados en pronósticos a corto plazo. En lo que se refiere al mediano plazo (de uno a tres años), se atiende en particular a indicadores macroeconómicos, en especial la política fiscal y monetaria. Sus pronósticos a largo plazo son más imprecisos, pero en ellos utiliza los mismos indicadores que para los pronósticos a mediano plazo, junto con los cambios estructurales que están ocurriendo en la economía.

3.5.2. FACTORES POR OBSERVAR

La ley de la oferta y la demanda determina el valor de mercado de las monedas en libre fluctuación. Sin embargo, muy pocas monedas flotan libremente, sin intervención gubernamental de ninguna clase; a la mayoría se les controla hasta cierto punto, lo que implica que los gobiernos deben tomar decisiones políticas sobre el valor de su moneda. Partiendo del supuesto de que los gobiernos controlan racionalmente el valor de la moneda (supuesto que quizá no es siempre realista), los administradores pueden vigilar los mismos factores de que se ocupa el gobierno con la intención de predecir ese valor. Tales factores son:

- ◆ Controles de capital.
- ◆ Diferenciales de los tipos de cambio.

- ◆ Estadísticas de la balanza de pagos.
- ◆ Reservas de divisas.
- ◆ Crecimiento del Producto Interno Bruto.
- ◆ Gasto gubernamental.
- ◆ Tasas de inflación relativas.
- ◆ Crecimiento de la oferta de dinero.
- ◆ Diferenciales de las tasas de interés.
- ◆ Tendencias en los movimientos de los tipos de cambio.

4. APLICACIÓN DE REDES NEURONALES PARA LA ESTIMACIÓN DEL COMPORTAMIENTO DE SISTEMAS CAMBIARIOS: ESTADO DEL ARTE

Teniendo en cuenta los trabajos realizados Chen y Leung (2004)⁵, y Mitra y Mitra (2006)⁶, podemos observar diferentes enfoques utilizados para la predicción de los tipos de cambio a través de las Redes Neuronales Artificiales.

En primer lugar, Chen y Leung hacen énfasis en la evolución y la mejor comprensión que en la última década han tenido las Redes Neuronales Artificiales para la toma de decisiones financieras. Su investigación está básicamente centrada en la evaluación del desempeño de dos (2) tipos de arquitecturas de Redes Neuronales Artificiales: Redes Neuronales Artificiales del tipo “feedforward” con varias capas intermedias y Redes Neuronales Artificiales de Regresión General. Como resultado, obtuvieron que existe una relación directa entre la selección del diseño adecuado de la arquitectura de la Red y el éxito en la predicción. Así mismo, pudieron notar que existe sinergia al momento de combinar los dos (2) tipos de arquitecturas de Redes Neuronales.

Por otro lado, el trabajo de Mitra y Mitra está basado en el empleo de Redes Neuronales Artificiales para la predicción de los tipos de cambio utilizando diferentes rangos de volatilidad en los precios al contado o spot. Como

⁵ An-Sing Chen y Mark T. Leung. Performance Evaluation of Neural Network Architectures: The Case of Predicting Foreign Exchange Correlations. National Chung Cheng University, Taiwan. University of Texas, San Antonio, USA. 2004. (p. 412)

⁶ Sharmishtha Mitra y Amit Mitra. Modeling Exchange rates using wavelet decomposed genetic neural networks. Department of Mathematics and Statistics, Indian Institute of Technology. Kanpur, India. 2006. (p. 114)

resultado, encontraron que el método es muy efectivo para realizar predicciones de los precios de los activos financieros.

5. METODOLOGÍA PROPUESTA

Para la construcción de las Redes Neuronales utilizaremos el software EasyNN-Plus V.8 (Easy Neural Network – Plus Version 8) desarrollado por la firma Neural Planner Software.

A través de este software se construirán diferentes Redes Neuronales de prueba utilizando como entradas las variables que se utilizan para predecir el valor del tipo de cambio, con el fin de encontrar la Red Neuronal Artificial que prediga de mejor manera los tipos de cambio futuros.

La información que será utilizada corresponde al año 2005, y se realizará la predicción de los primeros treinta (30) días del año 2006.

Para hallar la predicción en cada fecha, se introducen los valores de las variables de entrada vigentes durante los primeros treinta (30) días del año 2006, lo cual arroja de manera automática la predicción como salida de la red.

Los datos obtenidos en cada modelación de predicción se tabularán y se realizará una comparación con los tipos de cambios que estuvieron vigentes en cada fecha, con el fin de establecer cuál es la relación existente entre cada grupo de valores.

Así mismo, se analizarán variables como la importancia y sensibilidad de cada variable de entrada y la conexión entre neuronas.

6. REDES NEURONALES ARTIFICIALES: IMPLEMENTACIÓN

La finalidad de construir las Redes Neuronales Artificiales de prueba es identificar las variables que sirven para realizar una mejor predicción de los tipos de cambio, para lo cual se considerarán como entradas de la red las siguientes variables:

- ◆ Precios de cierre del dólar con respecto al peso (COP / USD)
- ◆ Día de la semana de cada precio de cierre
- ◆ Día hábil bursátil de cada precio de cierre
- ◆ Inflación de Colombia y Estados Unidos
- ◆ Tasas de Intervención del Emisor en Colombia y en Estados Unidos
- ◆ Producto Interno Bruto de Colombia y Estados Unidos
- ◆ Reservas Internacionales de Colombia
- ◆ Índice General de la Bolsa de Valores de Colombia
- ◆ Monto de negociación de dólares en Colombia realizadas a través del Sistema Electrónico de Negociación
- ◆ Agregado monetario M1 de Colombia

Cada Red Neuronal Artificial está compuesta por una matriz que contiene los datos diarios de las variables anteriormente mencionadas, considerando el precio de cierre del dólar con respecto al peso (COP / USD) como una variable de salida (output) y las demás como variables de entrada (input).

Para realizar la matriz se tuvo en cuenta el momento en el cual se conoce la información de cada variable, ya que variables como la inflación y el Producto Interno Bruto de un país durante un periodo (mes o trimestre respectivamente) se conocen durante el periodo siguiente; en el instante en

que existan variaciones en la tasa de intervención de un país esta es conocida inmediatamente, pero su vigencia comienza a regir a partir del día siguiente. Para el resto de las variables la información corresponde a la vigente para esa fecha y se refiere a la información disponible hasta el cierre de la jornada.

Para realizar las diferentes pruebas se utilizará el software Easy Neural Network – Plus Version 8, agregando en cada prueba diferentes combinaciones de variables. Una vez realizadas las diferentes Redes Neuronales Artificiales de prueba se procederá a analizar los resultados obtenidos.

REDES NEURONALES ARTIFICIALES DE PRUEBA

Se realizaron dieciocho (18) pruebas de Redes Neuronales Artificiales incluyendo en cada una de ellas diferentes variables de entrada. De acuerdo con lo establecido en el manual de usuario del software en la sección Network (Red), el software determina automáticamente el número óptimo de conexiones y capas intermedias.

De igual forma, establece que comúnmente no es necesaria más de una capa intermedia en una Red Neuronal Artificial, pero de manera manual es posible agregar hasta tres (3) capas intermedias.

Las variables de entrada utilizadas, los datos utilizados para la predicción y los resultados obtenidos en cada Red Neuronal Artificial de prueba se detallan a continuación:

Tabla 1. Variables de entrada utilizadas.

VARIABLES UTILIZADAS EN CADA RED NEURONAL ARTIFICIAL													
	Precio Cierre	Dia Sem	Dia Habil	IPC (1)	CPI (2)	Tasa Intervención	Fed Funds Rate	PIB (3)	GDP (4)	Reservas Int	IGBC (5)	Monto Neg Interbancario	M1 COL (6)
Prueba No. 1	X	X											
Prueba No. 2	X	X	X										
Prueba No. 3	X	X	X	X	X								
Prueba No. 4	X	X	X	X	X	X	X						
Prueba No. 5	X	X	X	X	X	X	X	X	X				
Prueba No. 6	X	X	X	X	X	X	X	X	X	X			
Prueba No. 7	X	X	X	X	X	X	X	X	X	X	X		
Prueba No. 8	X	X	X	X	X	X	X	X	X	X	X	X	
Prueba No. 9	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 10	X	X	X	X	X	X	X						
Prueba No. 11	X	X	X	X	X	X	X						
Prueba No. 12	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 13	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 14	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 15	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 16	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 17	X	X	X	X	X	X	X	X	X	X	X	X	X
Prueba No. 18	X	X	X	X	X	X	X	X	X	X	X	X	X

(1) IPC: Índice de Precios al Consumidor.

(2) CPI: Consumer Price Index.- Índice de Precios al Consumidor en Estados Unidos.

(3) PIB: Producto Interno Bruto.

(4) GDP: Gross Domestic Product.- Producto Interno Bruto en Estados Unidos.

(5) IGBC: Índice General de la Bolsa de Valores de Colombia.

(6) M1 COL: Agravado Monetario que indica la cantidad de efectivo en poder del público y los depósitos en cuenta corriente en los bancos.

Tabla 2. Datos utilizados para la predicción.

DATOS UTILIZADOS PARA LA PREDICCIÓN DE CADA RED NEURONAL ARTIFICIAL													
	Precio Cierre	Dia Sem	Dia Habil	IPC	CPI	Tasa Intervención	Fed Funds Rate	PIB	GDP	Reservas Int	IGBC	Monto Neg Interbancario	M1 COL
Prueba No. 1	LA PRUEBA ARROJÓ DEMASIADOS CICLOS DE APRENDIZAJE Y DE VALIDACION												
Prueba No. 2		Real	Real										
Prueba No. 3		Real	Real	Real	Real								
Prueba No. 4		Real	Real	Real	Real	Real	Real						
Prueba No. 5		Real	Real	Real	Real	Real	Real	Max	Max				
Prueba No. 6		Real	Real	Real	Real	Real	Real	Max	Max	Prom			
Prueba No. 7	LA PRUEBA ARROJÓ DEMASIADOS CICLOS DE APRENDIZAJE Y DE VALIDACION												
Prueba No. 8	LA PRUEBA ARROJÓ DEMASIADOS CICLOS DE APRENDIZAJE Y DE VALIDACION												
Prueba No. 9		Real	Real	Real	Real	Real	Real	Real	Max	Max	Max	Max	Max
Prueba No. 10		Real	Real	Real	Real	Real	Real						
Prueba No. 11	LA PRUEBA ARROJÓ DEMASIADOS CICLOS DE APRENDIZAJE Y DE VALIDACION												
Prueba No. 12		Real	Real	Real	Real	Real	Real	Real	Max	Max	Max	Max	Max
Prueba No. 13	LA PRUEBA ARROJÓ DEMASIADOS CICLOS DE APRENDIZAJE Y DE VALIDACION												
Prueba No. 14		Real	Real	Real	Real	Real	Real	Real	Max	Max	Max	Max	Max
Prueba No. 15		Real	Real	Real	Real	Real	Real	Prom	Prom	Prom	Prom	Prom	Prom
Prueba No. 16		Real	Real	Real	Real	Real	Real	Real	Max	Max	Max	Max	Max
Prueba No. 17		Real	Real	Real	Real	Real	Real	Real	Max	Max	Max	Max	Max
Prueba No. 18		Real	Real	Real	Real	Real	Real	Real	Min	Min	Min	Min	Min

Se debe tener en cuenta que los datos utilizados para la predicción en las pruebas No. 12, 14 y 15 el Monto de Negociación fue introducido como 0 en los días no hábiles, y para las pruebas No. 16 y 17 se utilizaron 220 y 150 campos de validación respectivamente; en los demás se utilizaron 190 campos de validación o aprendizaje.

Así mismo, de manera manual se estableció en las pruebas No. 10 y 12 que éstas tendrían dos (2) capas intermedias, y tres (3) capas intermedias en las pruebas No. 11 y 13.

RESULTADOS OBTENIDOS

En las pruebas No. 1, 7, 8, 11 y 13, no se obtuvieron resultados debido a que arrojaron demasiados ciclos de aprendizaje y validación.

Los resultados obtenidos en cada prueba se encuentran relacionados en el Apéndice A.

6.1. RELACIÓN ENTRE LOS RESULTADOS OBTENIDOS Y LOS TIPOS DE CAMBIO VIGENTES

A partir de los resultados obtenidos en cada prueba se puede medir la relación existente con los tipos de cambio vigentes; la cual será medida como la diferencia porcentual entre el promedio de los tipos de cambios vigentes y el promedio de los tipos de cambio pronosticados a través de las Redes Neuronales Artificiales, los cuales son:

Prueba No.	Porcentaje	Dif. Pesos
1	-	-
2	0.2574%	-5.85
3	0.8578%	-19.50
4	0.1276%	-2.90
5	0.0911%	-2.07
6	0.9414%	-21.40
7	-	-
8	-	-
9	0.0614%	-1.40
10	0.2326%	-5.29
11	-	-
12	0.3330%	-7.57
13	-	-
14	0.2692%	-6.12
15	2.2201%	-50.48
16	0.4633%	-10.54
17	0.4710%	-10.71
18	5.0261%	-114.28

Tabla 3. Diferencias entre los tipos de cambio vigentes y los tipos de cambio pronosticados.

La prueba que muestra una mayor relación entre los resultados obtenidos y los tipos de cambio vigentes, es decir, la que menos diferencia porcentual arrojó, fue la Prueba No. 9 con una diferencia porcentual de 0.0614% y una diferencia de \$1.40.

Las siguientes fueron las Pruebas No. 5 y 4 con diferencias porcentuales de 0.0911% y 0.1276% y con diferencias de \$2.07 y \$2.90, respectivamente.

6.2. RED NEURONAL ARTIFICIAL QUE MÁS SE ADAPTA A LA PREDICCIÓN

Para determinar la Red Neuronal Artificial (RNA) que más se adapta a la predicción, detallaremos los aspectos característicos de una RNA, tales como

topología, mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y forma de representación.

Se debe tener en cuenta, tal y como se mencionó anteriormente, y de acuerdo con lo establecido en el manual de usuario del software, en la sección Network (Red), al ingresar las variables de entrada y de salida, el software determina automáticamente el número óptimo de conexiones y capas intermedias. Así mismo, establece que comúnmente no es necesaria la utilización de más de una capa intermedia en una Red Neuronal Artificial.

TOPOLOGÍA

Todas las redes generadas por el software son redes multicapa de una (1) capa de entrada, una (1) capa intermedia y una (1) capa de salida. Las pruebas No. 10, 11, 12 y 13 generaron redes de similares características pero se agregaron de manera manual dos (2) o tres (3) capas intermedias.

Ninguna de las RNA generadas tienen neuronas cuyas salidas sean entradas de neuronas del mismo nivel o niveles precedentes, por lo tanto todas las RNA son del tipo feedforward o de propagación hacia delante.

MECANISMO DE APRENDIZAJE

A través del software es posible determinar el número de datos que servirán para el aprendizaje y el número de ciclos de aprendizaje que la red deba realizar; por lo tanto, las redes generadas por el software son redes con aprendizaje supervisado con un tipo de aprendizaje por corrección de error, ya que los pesos son ajustados con base en los valores de aprendizaje.

Para el caso de las pruebas No. 16 y 17 se utilizaron 220 y 150 campos de validación respectivamente, y en el resto se utilizaron 190 campos de validación o aprendizaje, teniendo en cuenta que el software escoge de manera aleatoria los campos que se utilizarán para el aprendizaje.

TIPO DE ASOCIACIÓN

Las Redes Neuronales Artificiales generadas por el software son las denominadas redes de heteroasociación, ya que las redes aprenden o se entrenan por parejas de datos. Lo anterior, puede ser fácilmente observado en las conexiones que genera cada neurona.

A manera de ejemplo, presentamos la forma como se generó la Red de Prueba 1, la cual con una (1) neurona en la capa de entrada generó seis (6) neuronas en la capa intermedia y doce (12) conexiones entre neuronas, que van desde la neurona 0 (neurona de entrada) hasta la neurona seis (6), y desde cada una de éstas hasta la neurona 7 (neurona de salida). Igualmente, presentamos los pesos de cada conexión.

connect	from	to	weight
0	0	1	-5.666466
1	0	2	-1.512372
2	0	3	-1.512368
3	0	4	-1.512371
4	0	5	-5.666461
5	0	6	-5.66662
6	1	7	6.91902
7	2	7	-8.493606
8	3	7	-8.51128
9	4	7	-8.505075
10	5	7	6.920705
11	6	7	6.849963

Tabla 4. Pesos entre las neuronas de la Prueba 1.

FORMA DE REPRESENTACIÓN

Debido a que el tipo de red que se quiere generar es para predicción de tipos de cambio, la forma como está representada la información de entrada y salida se encuentra representada en valores continuos, ya que durante cualquier periodo de tiempo el tipo de cambio peso-dólar varía dentro de un rango, con la posibilidad de alcanzar todos los infinitos valores que se encuentren dentro de ese rango.

6.3. COMPORTAMIENTO DE LAS VARIABLES DE LA RED NEURONAL ARTIFICIAL

El análisis del comportamiento de las variables de las Redes Neuronales Artificiales generadas por el software estará enfocado hacia cuatro (4) temas relevantes, que son: número de neuronas en cada red, importancia de cada variable de entrada, sensibilidad de cada variable de entrada y conexión entre neuronas.

NÚMERO DE NEURONAS EN CADA RED

A medida que se fueron realizando las pruebas se observa que un mayor número de neuronas en la capa de entrada no necesariamente implica un mayor número de neuronas en la (s) capa (s) intermedias, ya que en los casos donde existían doce (12) neuronas en la capa de entrada el software generó ocho (8) neuronas en la capa intermedia, y en la Prueba No. 6 donde existían nueve (9) neuronas en la capa de entrada el software también generó ocho (8) neuronas en la capa intermedia. Esta misma situación se presentó en las pruebas 2, 3, 4, 10 y 11, donde con 2, 4 y 6 neuronas en la

capa de entrada, el software generó cinco (5) neuronas en la capa intermedia.

En las pruebas No. 5 y 6 observamos que con ocho (8) y nueve (9) neuronas en la capa de entrada respectivamente, el software generó siete (7) y ocho (8) neuronas en la capa intermedia respectivamente; es decir, que, en estos casos el software generó un menor número de neuronas en la capa intermedia que el número de neuronas de la capa de entrada.

NUMERO DE NEURONAS					
	Capa de Entrada	Capa Intermedia			Capa de Salida
		1	2	3	
Prueba 1	1	6			1
Prueba 2	2	5			1
Prueba 3	4	5			1
Prueba 4	6	5			1
Prueba 5	8	7			1
Prueba 6	9	8			1
Prueba 7	10	6			1
Prueba 8	11	7			1
Prueba 9	12	8			1
Prueba 10	6	5	5		1
Prueba 11	6	5	5	5	1
Prueba 12	12	8	4		1
Prueba 13	12	8	4	6	1
Prueba 14	12	8			1
Prueba 15	12	8			1
Prueba 16	12	8			1
Prueba 17	12	8			1
Prueba 18	12	8			1

Tabla 5. Número de Neuronas en cada Red Neuronal Artificial de Prueba.

De igual forma notamos que no existe ninguna relación entre el número de neuronas en la (s) capa(s) intermedias y la diferencia porcentual entre los resultados obtenidos y los tipos de cambio vigentes.

IMPORTANCIA DE CADA VARIABLE DE ENTRADA

El software determina la importancia que cada variable de entrada tiene en la Red Neuronal Artificial, representada como la suma de los valores absolutos de los pesos de cada neurona de entrada hacia cada una de las neuronas de la capa intermedia.

La importancia de cada variable de entrada en cada una de las pruebas realizadas se encuentra relacionada en el Apéndice B.

SENSIBILIDAD DE CADA VARIABLE DE ENTRADA

De igual forma, el software determina la sensibilidad que cada variable de entrada tiene en la Red Neuronal Artificial, la cual está representada como la variación que tiene una variable de salida ante cambios en los valores de las variables de entrada. Para realizar este cálculo, se realiza un promedio de los valores de cada una de las variables de entrada incluidas en la matriz, luego el valor de cada variable es incrementado desde el valor mas bajo hasta el mas alto; los cambios que se producen en la variable de salida son calculados a medida que el valor de cada variable de entrada va incrementado, con el fin de medir la sensibilidad que tiene hacia el cambio. Se debe tener en cuenta que las variables que no son sensibles no son calculadas por el software.

La sensibilidad de cada variable de entrada en cada una de las pruebas realizadas se encuentra relacionada en el Apéndice C.

CONEXIÓN ENTRE NEURONAS

El cálculo de los pesos que existen en las conexiones entre neuronas es calculado por el software.

La sumatoria y el promedio de los pesos entre neuronas en cada prueba se detallan a continuación:

PESOS ENTRE NEURONAS		
Prueba	Sumatoria	Promedio
1	-26.356931	-2.196411
2	-26.260101	-1.750673
3	-337.335253	-13.49341
4	-52.860202	-1.510291
5	-153.920791	-2.443187
6	-180.206745	-2.252584
7	-78.901361	-1.195475
8	-279.113826	-3.322784
9	-110.022159	-1.057905
10	-155.060163	-2.584336
11	16.536291	0.194545
12	-11.557525	-0.087557
13	43.634922	0.27617
14	-109.17554	-1.049765
15	-109.559552	-1.053457
16	-96.68747	-0.929687
17	-75.310314	-0.724138
18	-110.022159	-1.057905

Tabla 6. Pesos de las Neuronas de cada Prueba.

De acuerdo con lo anterior en la mayoría de las pruebas, la sinapsis entre las neuronas es inhibitoria, ya que la sumatoria y el promedio de los pesos entre neuronas son negativos.

7. CONCLUSIONES

Como resultado de la investigación realizada, se ha podido comprobar que es posible realizar predicciones del tipo de cambio peso-dólar (COP / USD) utilizando Redes Neuronales Artificiales.

Se pudo determinar un modelo que muestra la mejor relación existente entre los resultados obtenidos y los tipos de cambio vigentes en las fechas de estudio, el cual está dado por una Red Neuronal Artificial de doce (12) neuronas en la capa de entrada, ocho (8) neuronas en la capa intermedia y una (1) neurona en la capa de salida; con una topología de red multicapa, feedforward o alimentada hacia delante; con un mecanismo de aprendizaje supervisado por corrección de errores; con heteroasociación y representada en forma de valores continuos.

De igual forma, el modelo mostró un margen de error promedio de 0.0614%, donde la variable mas importante de la predicción fue el IGBC (Índice General de la Bolsa de Valores de Colombia), y la variable con mayor sensibilidad fue Fed Funds Rate (Tasa de Interés de la Reserva Federal de Estados Unidos).

8. BIBLIOGRAFÍA

- [1] Sandra Patricia Daza P. Redes Neuronales Artificiales, fundamentos, modelos y aplicaciones. Universidad Militar Nueva Granada. Bogotá.
- [2] Maria Bonilla, Paulina Marco e Ignacio Olmeda. Redes Neuronales Artificiales: Predicción de la volatilidad del tipo de cambio de la peseta. Instituto Valenciano de Investigaciones Económicas. 2002.
- [3] John Daniels y Lee Radebaugh. Negocios Internacionales. 8va edición. Pearson Educación. 2000.
- [4] José R. Hilera y Victor J Martinez. Redes neuronales artificiales. Alfaomega. 2000. Madrid. España.
- [5] S. Y. Kung. Digital neural networks. PTR Prentice Hall, Inc. 1993.
- [6] Gustavo Vergel Cabrales. Metodología. Un manual para la elaboración de diseños y proyectos de investigación. Tercera edición.
- [7] Mario Tamayo y Tamayo. El proceso de la investigación científica. Limusa. Cuarta edición. 2002.
- [8] An-Sing Chen y Mark T. Leung. Performance Evaluation of Neural Network Architectures: The Case of Predicting Foreign Exchange Correlations. National Chung Cheng University, Taiwan. University of Texas, San Antonio, USA. 2004. (p. 412)
- [9] Sharmishtha Mitra y Amit Mitra. Modeling Exchange rates using wavelet decomposed genetic neural networks. Department of Mathematics and Statistics, Indian Institute of Technology. Kanpur, India. 2005. (p. 114)

APÉNDICE A.- RESULTADOS OBTENIDOS

Prueba 2

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2280.13	4.09	-0.18%
02/01/2006	2,284.22		2279.42	4.80	-0.21%
03/01/2006	2,284.22		2279.43	4.79	-0.21%
04/01/2006	2,282.27		2279.43	2.84	-0.12%
05/01/2006	2,282.13		2279.43	2.70	-0.12%
06/01/2006	2,279.99		2279.44	0.55	-0.02%
07/01/2006	2,278.40		2280.1	-1.70	0.07%
08/01/2006	2,278.40		2280.13	-1.73	0.08%
09/01/2006	2,278.40		2277.38	1.02	-0.04%
10/01/2006	2,278.40		2279.43	-1.03	0.05%
11/01/2006	2,276.58		2279.43	-2.85	0.13%
12/01/2006	2,274.73		2279.43	-4.70	0.21%
13/01/2006	2,274.59		2279.44	-4.85	0.21%
14/01/2006	2,273.31		2280.1	-6.79	0.30%
15/01/2006	2,273.31		2280.13	-6.82	0.30%
16/01/2006	2,273.31		2279.42	-6.11	0.27%
17/01/2006	2,273.31		2279.43	-6.12	0.27%
18/01/2006	2,270.88		2279.43	-8.55	0.38%
19/01/2006	2,271.55		2279.43	-7.88	0.35%
20/01/2006	2,269.70		2279.44	-9.74	0.43%
21/01/2006	2,269.41		2280.1	-10.69	0.47%
22/01/2006	2,269.41		2280.13	-10.72	0.47%
23/01/2006	2,269.41		2279.42	-10.01	0.44%
24/01/2006	2,262.04		2279.43	-17.39	0.77%
25/01/2006	2,262.87		2279.43	-16.56	0.73%
26/01/2006	2,273.50		2279.43	-5.93	0.26%
27/01/2006	2,270.85		2279.44	-8.59	0.38%
28/01/2006	2,266.66		2280.1	-13.44	0.59%
29/01/2006	2,266.66		2280.13	-13.47	0.59%
30/01/2006	2,266.66		2279.42	-12.76	0.56%
31/01/2006	2,265.65		2279.43	-13.78	0.61%
Promedio	2,273.71		2,279.56	-5.85	0.26%

Prueba 3

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2,294.98	-10.76	0.47%
02/01/2006	2,284.22		2,292.95	-8.73	0.38%
03/01/2006	2,284.22		2,292.57	-8.35	0.37%
04/01/2006	2,282.27		2,292.25	-9.98	0.44%
05/01/2006	2,282.13		2,291.95	-9.82	0.43%
06/01/2006	2,279.99		2,291.66	-11.67	0.51%
07/01/2006	2,278.40		2,295.15	-16.75	0.74%
08/01/2006	2,278.40		2,294.98	-16.58	0.73%
09/01/2006	2,278.40		2,296.10	-17.70	0.78%
10/01/2006	2,278.40		2,292.57	-14.17	0.62%
11/01/2006	2,276.58		2,292.25	-15.67	0.69%
12/01/2006	2,274.73		2,291.95	-17.22	0.76%
13/01/2006	2,274.59		2,291.66	-17.07	0.75%
14/01/2006	2,273.31		2,295.15	-21.84	0.96%
15/01/2006	2,273.31		2,294.98	-21.67	0.95%
16/01/2006	2,273.31		2,292.95	-19.64	0.86%
17/01/2006	2,273.31		2,292.57	-19.26	0.85%
18/01/2006	2,270.88		2,292.25	-21.37	0.94%
19/01/2006	2,271.55		2,291.95	-20.40	0.90%
20/01/2006	2,269.70		2,291.66	-21.96	0.97%
21/01/2006	2,269.41		2,295.15	-25.74	1.13%
22/01/2006	2,269.41		2,294.98	-25.57	1.13%
23/01/2006	2,269.41		2,292.95	-23.54	1.04%
24/01/2006	2,262.04		2,292.57	-30.53	1.35%
25/01/2006	2,262.87		2,292.25	-29.38	1.30%
26/01/2006	2,273.50		2,291.95	-18.45	0.81%
27/01/2006	2,270.85		2,291.66	-20.81	0.92%
28/01/2006	2,266.66		2,295.15	-28.49	1.26%
29/01/2006	2,266.66		2,294.98	-28.32	1.25%
30/01/2006	2,266.66		2,292.95	-26.29	1.16%
31/01/2006	2,265.65		2,292.57	-26.92	1.19%
Promedio	2,273.71		2,293.22	-19.50	0.86%

Prueba 4

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2277.57	6.65	-0.29%
02/01/2006	2,284.22	2274.61	9.61	-0.42%
03/01/2006	2,284.22	2274.69	9.53	-0.42%
04/01/2006	2,282.27	2274.78	7.49	-0.33%
05/01/2006	2,282.13	2274.87	7.26	-0.32%
06/01/2006	2,279.99	2274.95	5.04	-0.22%
07/01/2006	2,278.40	2278.3	0.10	0.00%
08/01/2006	2,278.40	2277.57	0.83	-0.04%
09/01/2006	2,278.40	2303.64	-25.24	1.11%
10/01/2006	2,278.40	2274.69	3.71	-0.16%
11/01/2006	2,276.58	2274.78	1.80	-0.08%
12/01/2006	2,274.73	2274.87	-0.14	0.01%
13/01/2006	2,274.59	2274.95	-0.36	0.02%
14/01/2006	2,273.31	2278.3	-4.99	0.22%
15/01/2006	2,273.31	2277.57	-4.26	0.19%
16/01/2006	2,273.31	2274.61	-1.30	0.06%
17/01/2006	2,273.31	2274.69	-1.38	0.06%
18/01/2006	2,270.88	2274.78	-3.90	0.17%
19/01/2006	2,271.55	2274.87	-3.32	0.15%
20/01/2006	2,269.70	2274.95	-5.25	0.23%
21/01/2006	2,269.41	2278.3	-8.89	0.39%
22/01/2006	2,269.41	2277.57	-8.16	0.36%
23/01/2006	2,269.41	2274.61	-5.20	0.23%
24/01/2006	2,262.04	2274.69	-12.65	0.56%
25/01/2006	2,262.87	2274.78	-11.91	0.53%
26/01/2006	2,273.50	2274.87	-1.37	0.06%
27/01/2006	2,270.85	2274.95	-4.10	0.18%
28/01/2006	2,266.66	2278.3	-11.64	0.51%
29/01/2006	2,266.66	2277.57	-10.91	0.48%
30/01/2006	2,266.66	2274.61	-7.95	0.35%
31/01/2006	2,265.65	2274.69	-9.04	0.40%
Promedio	2,273.71	2,276.61	-2.90	0.13%

Prueba 5

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2,273.42	10.80	-0.47%
02/01/2006	2,284.22	2,276.90	7.32	-0.32%
03/01/2006	2,284.22	2,276.91	7.31	-0.32%
04/01/2006	2,282.27	2,276.92	5.35	-0.23%
05/01/2006	2,282.13	2,276.93	5.20	-0.23%
06/01/2006	2,279.99	2,276.94	3.05	-0.13%
07/01/2006	2,278.40	2,273.39	5.01	-0.22%
08/01/2006	2,278.40	2,273.42	4.98	-0.22%
09/01/2006	2,278.40	2,273.25	5.15	-0.23%
10/01/2006	2,278.40	2,276.91	1.49	-0.07%
11/01/2006	2,276.58	2,276.92	-0.34	0.01%
12/01/2006	2,274.73	2,276.93	-2.20	0.10%
13/01/2006	2,274.59	2,276.94	-2.35	0.10%
14/01/2006	2,273.31	2,273.39	-0.08	0.00%
15/01/2006	2,273.31	2,273.42	-0.11	0.00%
16/01/2006	2,273.31	2,276.90	-3.59	0.16%
17/01/2006	2,273.31	2,276.91	-3.60	0.16%
18/01/2006	2,270.88	2,276.92	-6.04	0.27%
19/01/2006	2,271.55	2,276.93	-5.38	0.24%
20/01/2006	2,269.70	2,276.94	-7.24	0.32%
21/01/2006	2,269.41	2,273.39	-3.98	0.18%
22/01/2006	2,269.41	2,273.42	-4.01	0.18%
23/01/2006	2,269.41	2,276.90	-7.49	0.33%
24/01/2006	2,262.04	2,276.91	-14.87	0.66%
25/01/2006	2,262.87	2,276.92	-14.05	0.62%
26/01/2006	2,273.50	2,276.93	-3.43	0.15%
27/01/2006	2,270.85	2,276.94	-6.09	0.27%
28/01/2006	2,266.66	2,273.39	-6.73	0.30%
29/01/2006	2,266.66	2,273.42	-6.76	0.30%
30/01/2006	2,266.66	2,276.90	-10.24	0.45%
31/01/2006	2,265.65	2,276.91	-11.26	0.50%
Promedio	2,273.71	2,275.78	-2.07	0.09%

Prueba 6

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2,292.11	-7.89	0.35%
02/01/2006	2,284.22	2,295.52	-11.30	0.49%
03/01/2006	2,284.22	2,298.55	-14.33	0.63%
04/01/2006	2,282.27	2,297.33	-15.06	0.66%
05/01/2006	2,282.13	2,296.12	-13.99	0.61%
06/01/2006	2,279.99	2,295.13	-15.14	0.66%
07/01/2006	2,278.40	2,292.11	-13.71	0.60%
08/01/2006	2,278.40	2,292.11	-13.71	0.60%
09/01/2006	2,278.40	2,290.42	-12.02	0.53%
10/01/2006	2,278.40	2,298.55	-20.15	0.88%
11/01/2006	2,276.58	2,297.33	-20.75	0.91%
12/01/2006	2,274.73	2,296.12	-21.39	0.94%
13/01/2006	2,274.59	2,295.13	-20.54	0.90%
14/01/2006	2,273.31	2,292.11	-18.80	0.83%
15/01/2006	2,273.31	2,292.11	-18.80	0.83%
16/01/2006	2,273.31	2,295.52	-22.21	0.98%
17/01/2006	2,273.31	2,298.55	-25.24	1.11%
18/01/2006	2,270.88	2,297.33	-26.45	1.16%
19/01/2006	2,271.55	2,296.12	-24.57	1.08%
20/01/2006	2,269.70	2,295.13	-25.43	1.12%
21/01/2006	2,269.41	2,292.11	-22.70	1.00%
22/01/2006	2,269.41	2,292.11	-22.70	1.00%
23/01/2006	2,269.41	2,295.52	-26.11	1.15%
24/01/2006	2,262.04	2,298.55	-36.51	1.61%
25/01/2006	2,262.87	2,297.33	-34.46	1.52%
26/01/2006	2,273.50	2,296.12	-22.62	0.99%
27/01/2006	2,270.85	2,295.13	-24.28	1.07%
28/01/2006	2,266.66	2,292.11	-25.45	1.12%
29/01/2006	2,266.66	2,292.11	-25.45	1.12%
30/01/2006	2,266.66	2,295.52	-28.86	1.27%
31/01/2006	2,265.65	2,298.55	-32.90	1.45%
Promedio	2,273.71	2,295.11	-21.40	0.94%

Prueba 9

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2276.9	7.32	-0.32%
02/01/2006	2,284.22	2274.32	9.90	-0.43%
03/01/2006	2,284.22	2274.38	9.84	-0.43%
04/01/2006	2,282.27	2274.5	7.77	-0.34%
05/01/2006	2,282.13	2274.75	7.38	-0.32%
06/01/2006	2,279.99	2275.29	4.70	-0.21%
07/01/2006	2,278.40	2275.51	2.89	-0.13%
08/01/2006	2,278.40	2276.9	1.50	-0.07%
09/01/2006	2,278.40	2274.43	3.97	-0.17%
10/01/2006	2,278.40	2274.38	4.02	-0.18%
11/01/2006	2,276.58	2274.5	2.08	-0.09%
12/01/2006	2,274.73	2274.75	-0.02	0.00%
13/01/2006	2,274.59	2275.29	-0.70	0.03%
14/01/2006	2,273.31	2275.51	-2.20	0.10%
15/01/2006	2,273.31	2276.9	-3.59	0.16%
16/01/2006	2,273.31	2274.32	-1.01	0.04%
17/01/2006	2,273.31	2274.38	-1.07	0.05%
18/01/2006	2,270.88	2274.5	-3.62	0.16%
19/01/2006	2,271.55	2274.75	-3.20	0.14%
20/01/2006	2,269.70	2275.29	-5.59	0.25%
21/01/2006	2,269.41	2275.51	-6.10	0.27%
22/01/2006	2,269.41	2276.9	-7.49	0.33%
23/01/2006	2,269.41	2274.32	-4.91	0.22%
24/01/2006	2,262.04	2274.38	-12.34	0.55%
25/01/2006	2,262.87	2274.5	-11.63	0.51%
26/01/2006	2,273.50	2274.75	-1.25	0.05%
27/01/2006	2,270.85	2275.29	-4.44	0.20%
28/01/2006	2,266.66	2275.51	-8.85	0.39%
29/01/2006	2,266.66	2276.9	-10.24	0.45%
30/01/2006	2,266.66	2274.32	-7.66	0.34%
31/01/2006	2,265.65	2274.38	-8.73	0.39%
Promedio	2,273.71	2,275.11	-1.40	0.06%

Prueba 10

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2279	5.22	-0.23%
02/01/2006	2,284.22	2279	5.22	-0.23%
03/01/2006	2,284.22	2279	5.22	-0.23%
04/01/2006	2,282.27	2279	3.27	-0.14%
05/01/2006	2,282.13	2278.99	3.14	-0.14%
06/01/2006	2,279.99	2278.99	1.00	-0.04%
07/01/2006	2,278.40	2279	-0.60	0.03%
08/01/2006	2,278.40	2279	-0.60	0.03%
09/01/2006	2,278.40	2279.06	-0.66	0.03%
10/01/2006	2,278.40	2279	-0.60	0.03%
11/01/2006	2,276.58	2279	-2.42	0.11%
12/01/2006	2,274.73	2278.99	-4.26	0.19%
13/01/2006	2,274.59	2278.99	-4.40	0.19%
14/01/2006	2,273.31	2279	-5.69	0.25%
15/01/2006	2,273.31	2279	-5.69	0.25%
16/01/2006	2,273.31	2279	-5.69	0.25%
17/01/2006	2,273.31	2279	-5.69	0.25%
18/01/2006	2,270.88	2279	-8.12	0.36%
19/01/2006	2,271.55	2278.99	-7.44	0.33%
20/01/2006	2,269.70	2278.99	-9.29	0.41%
21/01/2006	2,269.41	2279	-9.59	0.42%
22/01/2006	2,269.41	2279	-9.59	0.42%
23/01/2006	2,269.41	2279	-9.59	0.42%
24/01/2006	2,262.04	2279	-16.96	0.75%
25/01/2006	2,262.87	2279	-16.13	0.71%
26/01/2006	2,273.50	2278.99	-5.49	0.24%
27/01/2006	2,270.85	2278.99	-8.14	0.36%
28/01/2006	2,266.66	2279	-12.34	0.54%
29/01/2006	2,266.66	2279	-12.34	0.54%
30/01/2006	2,266.66	2279	-12.34	0.54%
31/01/2006	2,265.65	2279	-13.35	0.59%
Promedio	2,273.71	2,279.00	-5.29	0.23%

Prueba 12

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2282.61	1.61	-0.07%
02/01/2006	2,284.22	2279.5	4.72	-0.21%
03/01/2006	2,284.22	2280.24	3.98	-0.17%
04/01/2006	2,282.27	2280.85	1.42	-0.06%
05/01/2006	2,282.13	2281.33	0.80	-0.04%
06/01/2006	2,279.99	2281.68	-1.69	0.07%
07/01/2006	2,278.40	2282.61	-4.21	0.18%
08/01/2006	2,278.40	2282.61	-4.21	0.18%
09/01/2006	2,278.40	2281.62	-3.22	0.14%
10/01/2006	2,278.40	2280.24	-1.84	0.08%
11/01/2006	2,276.58	2280.85	-4.27	0.19%
12/01/2006	2,274.73	2281.33	-6.60	0.29%
13/01/2006	2,274.59	2281.68	-7.09	0.31%
14/01/2006	2,273.31	2282.61	-9.30	0.41%
15/01/2006	2,273.31	2282.61	-9.30	0.41%
16/01/2006	2,273.31	2279.5	-6.19	0.27%
17/01/2006	2,273.31	2280.24	-6.93	0.30%
18/01/2006	2,270.88	2280.85	-9.97	0.44%
19/01/2006	2,271.55	2281.33	-9.78	0.43%
20/01/2006	2,269.70	2281.68	-11.98	0.53%
21/01/2006	2,269.41	2282.61	-13.20	0.58%
22/01/2006	2,269.41	2282.61	-13.20	0.58%
23/01/2006	2,269.41	2279.5	-10.09	0.44%
24/01/2006	2,262.04	2280.24	-18.20	0.80%
25/01/2006	2,262.87	2280.85	-17.98	0.79%
26/01/2006	2,273.50	2281.33	-7.83	0.34%
27/01/2006	2,270.85	2281.68	-10.83	0.48%
28/01/2006	2,266.66	2282.61	-15.95	0.70%
29/01/2006	2,266.66	2282.61	-15.95	0.70%
30/01/2006	2,266.66	2279.5	-12.84	0.57%
31/01/2006	2,265.65	2280.24	-14.59	0.64%
Promedio	2,273.71	2,281.28	-7.57	0.33%

Prueba 14

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2295.99	-11.77	0.52%
02/01/2006	2,284.22		2274.31	9.91	-0.43%
03/01/2006	2,284.22		2274.35	9.87	-0.43%
04/01/2006	2,282.27		2274.46	7.81	-0.34%
05/01/2006	2,282.13		2274.69	7.44	-0.33%
06/01/2006	2,279.99		2275.18	4.81	-0.21%
07/01/2006	2,278.40		2288.45	-10.05	0.44%
08/01/2006	2,278.40		2295.99	-17.59	0.77%
09/01/2006	2,278.40		2274.74	3.66	-0.16%
10/01/2006	2,278.40		2274.35	4.05	-0.18%
11/01/2006	2,276.58		2274.46	2.12	-0.09%
12/01/2006	2,274.73		2274.69	0.04	0.00%
13/01/2006	2,274.59		2275.18	-0.59	0.03%
14/01/2006	2,273.31		2288.45	-15.14	0.67%
15/01/2006	2,273.31		2295.99	-22.68	1.00%
16/01/2006	2,273.31		2274.31	-1.00	0.04%
17/01/2006	2,273.31		2274.35	-1.04	0.05%
18/01/2006	2,270.88		2274.46	-3.58	0.16%
19/01/2006	2,271.55		2274.69	-3.14	0.14%
20/01/2006	2,269.70		2275.18	-5.48	0.24%
21/01/2006	2,269.41		2288.45	-19.04	0.84%
22/01/2006	2,269.41		2295.99	-26.58	1.17%
23/01/2006	2,269.41		2274.31	-4.90	0.22%
24/01/2006	2,262.04		2274.35	-12.31	0.54%
25/01/2006	2,262.87		2274.46	-11.59	0.51%
26/01/2006	2,273.50		2274.69	-1.19	0.05%
27/01/2006	2,270.85		2275.18	-4.33	0.19%
28/01/2006	2,266.66		2288.45	-21.79	0.96%
29/01/2006	2,266.66		2295.99	-29.33	1.29%
30/01/2006	2,266.66		2274.31	-7.65	0.34%
31/01/2006	2,265.65		2274.35	-8.70	0.38%
Promedio	2,273.71		2,279.83	-6.12	0.27%

Prueba 15

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2,296.89	-12.67	0.55%
02/01/2006	2,284.22		2,353.09	-68.87	3.02%
03/01/2006	2,284.22		2,342.72	-58.50	2.56%
04/01/2006	2,282.27		2,330.91	-48.64	2.13%
05/01/2006	2,282.13		2,318.66	-36.53	1.60%
06/01/2006	2,279.99		2,307.13	-27.14	1.19%
07/01/2006	2,278.40		2,307.85	-29.45	1.29%
08/01/2006	2,278.40		2,296.89	-18.49	0.81%
09/01/2006	2,278.40		2,381.27	-102.87	4.52%
10/01/2006	2,278.40		2,342.72	-64.32	2.82%
11/01/2006	2,276.58		2,330.91	-54.33	2.39%
12/01/2006	2,274.73		2,318.66	-43.93	1.93%
13/01/2006	2,274.59		2,307.13	-32.54	1.43%
14/01/2006	2,273.31		2,307.85	-34.54	1.52%
15/01/2006	2,273.31		2,296.89	-23.58	1.04%
16/01/2006	2,273.31		2,353.09	-79.78	3.51%
17/01/2006	2,273.31		2,342.72	-69.41	3.05%
18/01/2006	2,270.88		2,330.91	-60.03	2.64%
19/01/2006	2,271.55		2,318.66	-47.11	2.07%
20/01/2006	2,269.70		2,307.13	-37.43	1.65%
21/01/2006	2,269.41		2,307.85	-38.44	1.69%
22/01/2006	2,269.41		2,296.89	-27.48	1.21%
23/01/2006	2,269.41		2,353.09	-83.68	3.69%
24/01/2006	2,262.04		2,342.72	-80.68	3.57%
25/01/2006	2,262.87		2,330.91	-68.04	3.01%
26/01/2006	2,273.50		2,318.66	-45.16	1.99%
27/01/2006	2,270.85		2,307.13	-36.28	1.60%
28/01/2006	2,266.66		2,307.85	-41.19	1.82%
29/01/2006	2,266.66		2,296.89	-30.23	1.33%
30/01/2006	2,266.66		2,353.09	-86.43	3.81%
31/01/2006	2,265.65		2,342.72	-77.07	3.40%
Promedio	2,273.71		2,324.19	-50.48	2.22%

Prueba 16

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2,290.14	-5.92	0.26%
02/01/2006	2,284.22		2,278.39	5.83	-0.26%
03/01/2006	2,284.22		2,280.93	3.29	-0.14%
04/01/2006	2,282.27		2,283.02	-0.75	0.03%
05/01/2006	2,282.13		2,284.46	-2.33	0.10%
06/01/2006	2,279.99		2,285.51	-5.52	0.24%
07/01/2006	2,278.40		2,287.80	-9.40	0.41%
08/01/2006	2,278.40		2,290.14	-11.74	0.52%
09/01/2006	2,278.40		2,279.56	-1.16	0.05%
10/01/2006	2,278.40		2,280.93	-2.53	0.11%
11/01/2006	2,276.58		2,283.02	-6.44	0.28%
12/01/2006	2,274.73		2,284.46	-9.73	0.43%
13/01/2006	2,274.59		2,285.51	-10.92	0.48%
14/01/2006	2,273.31		2,287.80	-14.49	0.64%
15/01/2006	2,273.31		2,290.14	-16.83	0.74%
16/01/2006	2,273.31		2,278.39	-5.08	0.22%
17/01/2006	2,273.31		2,280.93	-7.62	0.34%
18/01/2006	2,270.88		2,283.02	-12.14	0.53%
19/01/2006	2,271.55		2,284.46	-12.91	0.57%
20/01/2006	2,269.70		2,285.51	-15.81	0.70%
21/01/2006	2,269.41		2,287.80	-18.39	0.81%
22/01/2006	2,269.41		2,290.14	-20.73	0.91%
23/01/2006	2,269.41		2,278.39	-8.98	0.40%
24/01/2006	2,262.04		2,280.93	-18.89	0.84%
25/01/2006	2,262.87		2,283.02	-20.15	0.89%
26/01/2006	2,273.50		2,284.46	-10.96	0.48%
27/01/2006	2,270.85		2,285.51	-14.66	0.65%
28/01/2006	2,266.66		2,287.80	-21.14	0.93%
29/01/2006	2,266.66		2,290.14	-23.48	1.04%
30/01/2006	2,266.66		2,278.39	-11.73	0.52%
31/01/2006	2,265.65		2,280.93	-15.28	0.67%
Promedio	2,273.71		2,284.25	-10.54	0.46%

Prueba 17

Fecha	Precio Real	Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22	2,283.99	0.23	-0.01%
02/01/2006	2,284.22	2,277.34	6.88	-0.30%
03/01/2006	2,284.22	2,279.99	4.23	-0.19%
04/01/2006	2,282.27	2,284.78	-2.51	0.11%
05/01/2006	2,282.13	2,289.93	-7.80	0.34%
06/01/2006	2,279.99	2,293.35	-13.36	0.59%
07/01/2006	2,278.40	2,283.36	-4.96	0.22%
08/01/2006	2,278.40	2,283.99	-5.59	0.25%
09/01/2006	2,278.40	2,282.08	-3.68	0.16%
10/01/2006	2,278.40	2,279.99	-1.59	0.07%
11/01/2006	2,276.58	2,284.78	-8.20	0.36%
12/01/2006	2,274.73	2,289.93	-15.20	0.67%
13/01/2006	2,274.59	2,293.35	-18.76	0.82%
14/01/2006	2,273.31	2,283.36	-10.05	0.44%
15/01/2006	2,273.31	2,283.99	-10.68	0.47%
16/01/2006	2,273.31	2,277.34	-4.03	0.18%
17/01/2006	2,273.31	2,279.99	-6.68	0.29%
18/01/2006	2,270.88	2,284.78	-13.90	0.61%
19/01/2006	2,271.55	2,289.93	-18.38	0.81%
20/01/2006	2,269.70	2,293.35	-23.65	1.04%
21/01/2006	2,269.41	2,283.36	-13.95	0.61%
22/01/2006	2,269.41	2,283.99	-14.58	0.64%
23/01/2006	2,269.41	2,277.34	-7.93	0.35%
24/01/2006	2,262.04	2,279.99	-17.95	0.79%
25/01/2006	2,262.87	2,284.78	-21.91	0.97%
26/01/2006	2,273.50	2,289.93	-16.43	0.72%
27/01/2006	2,270.85	2,293.35	-22.50	0.99%
28/01/2006	2,266.66	2,283.36	-16.70	0.74%
29/01/2006	2,266.66	2,283.99	-17.33	0.76%
30/01/2006	2,266.66	2,277.34	-10.68	0.47%
31/01/2006	2,265.65	2,279.99	-14.34	0.63%
Promedio	2,273.71	2,284.42	-10.71	0.47%

Prueba 18

Fecha	Precio Real		Pronóstico	Dif. Pesos	Dif. Porcentual
01/01/2006	2,284.22		2,396.32	-112.10	4.91%
02/01/2006	2,284.22		2,375.90	-91.68	4.01%
03/01/2006	2,284.22		2,382.86	-98.64	4.32%
04/01/2006	2,282.27		2,386.51	-104.24	4.57%
05/01/2006	2,282.13		2,388.38	-106.25	4.66%
06/01/2006	2,279.99		2,389.08	-109.09	4.78%
07/01/2006	2,278.40		2,396.24	-117.84	5.17%
08/01/2006	2,278.40		2,396.32	-117.92	5.18%
09/01/2006	2,278.40		2,387.36	-108.96	4.78%
10/01/2006	2,278.40		2,382.86	-104.46	4.58%
11/01/2006	2,276.58		2,386.51	-109.93	4.83%
12/01/2006	2,274.73		2,388.38	-113.65	5.00%
13/01/2006	2,274.59		2,389.08	-114.49	5.03%
14/01/2006	2,273.31		2,396.24	-122.93	5.41%
15/01/2006	2,273.31		2,396.32	-123.01	5.41%
16/01/2006	2,273.31		2,375.90	-102.59	4.51%
17/01/2006	2,273.31		2,382.86	-109.55	4.82%
18/01/2006	2,270.88		2,386.51	-115.63	5.09%
19/01/2006	2,271.55		2,388.38	-116.83	5.14%
20/01/2006	2,269.70		2,389.08	-119.38	5.26%
21/01/2006	2,269.41		2,396.24	-126.83	5.59%
22/01/2006	2,269.41		2,396.32	-126.91	5.59%
23/01/2006	2,269.41		2,375.90	-106.49	4.69%
24/01/2006	2,262.04		2,382.86	-120.82	5.34%
25/01/2006	2,262.87		2,386.51	-123.64	5.46%
26/01/2006	2,273.50		2,388.38	-114.88	5.05%
27/01/2006	2,270.85		2,389.08	-118.23	5.21%
28/01/2006	2,266.66		2,396.24	-129.58	5.72%
29/01/2006	2,266.66		2,396.32	-129.66	5.72%
30/01/2006	2,266.66		2,375.90	-109.24	4.82%
31/01/2006	2,265.65		2,382.86	-117.21	5.17%
Promedio	2,273.71		2,387.99	-114.28	5.03%

APÉNDICE B.- IMPORTANCIA DE CADA VARIABLE DE ENTRADA

Prueba 1

Column	Input	Node	Importance
1	Dia Sem	0	21.536657

Prueba 2

Column	Input	Node	Importance
1	Dia Sem	0	9.591665
2	Dia Habil	1	19.352857

Prueba 3

Column	Input	Node	Importance
1	Dia Sem	0	37.269558
2	Dia Habil	1	28.33523
3	IPC	2	252.885612
4	CPI	3	377.649519

Prueba 4

Column	Input	Node	Importance
1	Dia Sem	0	29.770014
2	Dia Habil	1	36.208118
3	IPC	2	101.926521
4	CPI	3	128.340811
5	Tasa Intervencion	4	40.788237
6	Fed Funds Rate	5	88.733498

Prueba 5

Column	Input	Node	Importance
1	Dia Sem	0	77.646977
2	Dia Habil	1	65.334622
3	IPC	2	123.815429
4	CPI	3	75.167613
5	Tasa Intervencion	4	48.800834
6	Fed Funds Rate	5	166.915854
7	PIB	6	67.040211
8	GDP	7	30.875761

Prueba 6

Column	Input	Node	Importance
1	Dia Sem	0	89.339677
2	Dia Habil	1	49.5301
3	IPC	2	240.247487
4	CPI	3	109.898869
5	Tasa Intervencion	4	91.113455
6	Fed Funds Rate	5	224.302845
7	PIB	6	119.76016
8	GDP	7	128.642572
9	Reservas Int	8	442.740635

Prueba 7

Column	Input	Node	Importance
1	Dia Sem	0	14.850418
2	Dia Habil	1	33.448974
3	IPC	2	173.808093
4	CPI	3	148.650717
5	Tasa Intervencion	4	62.870398
6	Fed Funds Rate	5	233.192433
7	PIB	6	145.654389
8	GDP	7	203.065857
9	Reservas Int	8	325.092915
10	IGBC	9	255.839744

Prueba 8

Column	Input	Node	Importance
1	Dia Sem	0	21.945037
2	Dia Habil	1	116.958318
3	IPC	2	263.472037
4	CPI	3	33.471616
5	Tasa Intervencion	4	49.62181
6	Fed Funds Rate	5	237.83532
7	PIB	6	85.410766
8	GDP	7	88.346032
9	Reservas Int	8	235.907214
10	IGBC	9	334.818811
11	Monto Neg Interbancario	10	71.63799

Prueba 9

Column	Input	Node	Importance
1	Dia Sem	0	14.991471
2	Dia Habil	1	15.517761
3	IPC	2	46.331112
4	CPI	3	42.08391
5	Tasa Intervencion	4	25.879993
6	Fed Funds Rate	5	62.548605
7	PIB	6	22.82436
8	GDP	7	23.005415
9	Reservas Int	8	50.350686
10	IGBC	9	74.842042
11	Monto Neg Interbancario	10	36.60068
12	M1 COL	11	67.583548

Prueba 10

Column	Input	Node	Importance
1	Dia Sem	0	8.738596
2	Dia Habil	1	9.858843
3	IPC	2	68.639977
4	CPI	3	50.357754
5	Tasa Intervencion	4	22.784003
6	Fed Funds Rate	5	44.419472

Prueba 11

Column	Input	Node	Importance
1	Dia Sem	0	16.195873
2	Dia Habil	1	36.750829
3	IPC	2	87.352674
4	CPI	3	16.176023
5	Tasa Intervencion	4	39.972887
6	Fed Funds Rate	5	114.555604

Prueba 12

Column	Input	Node	Importance
1	Dia Sem	0	21.309747
2	Dia Habil	1	28.187927
3	IPC	2	102.970896
4	CPI	3	74.679376
5	Tasa Intervencion	4	53.893669
6	Fed Funds Rate	5	40.956508
7	PIB	6	46.032949
8	GDP	7	57.071116
9	Reservas Int	8	88.346813
10	IGBC	9	89.039498
11	Monto Neg Interbancario	10	11.505015
12	M1 COL	11	49.858315

Prueba 13

Column	Input	Node	Importance
1	Dia Sem	0	9.763509
2	Dia Habil	1	3.183161
3	IPC	2	30.09189
4	CPI	3	4.637158
5	Tasa Intervencion	4	7.941193
6	Fed Funds Rate	5	34.910832
7	PIB	6	13.05981
8	GDP	7	32.796286
9	Reservas Int	8	26.272927
10	IGBC	9	31.170637
11	Monto Neg Interbancario	10	2.565031
12	M1 COL	11	6.998584

Prueba 14

Column	Input	Node	Importance
1	Dia Sem	0	14.636455
2	Dia Habil	1	15.514886
3	IPC	2	46.125045
4	CPI	3	41.433922
5	Tasa Intervencion	4	26.048159
6	Fed Funds Rate	5	61.818014
7	PIB	6	22.504217
8	GDP	7	23.010058
9	Reservas Int	8	49.673866
10	IGBC	9	74.326817
11	Monto Neg Interbancario	10	36.408054
12	M1 COL	11	66.093366

Prueba 15

Column	Input	Node	Importance
1	Dia Sem	0	14.687878
2	Dia Habil	1	15.520769
3	IPC	2	46.065023
4	CPI	3	41.495404
5	Tasa Intervencion	4	25.950638
6	Fed Funds Rate	5	61.863424
7	PIB	6	22.546787
8	GDP	7	22.984946
9	Reservas Int	8	49.825739
10	IGBC	9	74.383889
11	Monto Neg Interbancario	10	36.405764
12	M1 COL	11	66.299208

Prueba 16

Column	Input	Node	Importance
1	Dia Sem	0	16.1063
2	Dia Habil	1	21.453707
3	IPC	2	18.933295
4	CPI	3	25.977058
5	Tasa Intervencion	4	19.583114
6	Fed Funds Rate	5	29.393141
7	PIB	6	19.419112
8	GDP	7	14.001916
9	Reservas Int	8	39.934813
10	IGBC	9	55.262042
11	Monto Neg Interbancario	10	22.111819
12	M1 COL	11	56.898668

Prueba 17

Column	Input	Node	Importance
1	Dia Sem	0	21.411105
2	Dia Habil	1	17.044477
3	IPC	2	55.394749
4	CPI	3	42.845482
5	Tasa Intervencion	4	26.136581
6	Fed Funds Rate	5	53.287917
7	PIB	6	29.674375
8	GDP	7	25.2847
9	Reservas Int	8	60.135785
10	IGBC	9	75.398872
11	Monto Neg Interbancario	10	19.737185
12	M1 COL	11	42.90013

Prueba 18

Column	Input	Node	Importance
1	Dia Sem	0	14.991471
2	Dia Habil	1	15.517761
3	IPC	2	46.331112
4	CPI	3	42.08391
5	Tasa Intervencion	4	25.879993
6	Fed Funds Rate	5	62.548605
7	PIB	6	22.82436
8	GDP	7	23.005415
9	Reservas Int	8	50.350686
10	IGBC	9	74.842042
11	Monto Neg Interbancario	10	36.60068
12	M1 COL	11	67.583548

Resumen

Prueba	Input	Importance
1	Dia Sem	21.536657
2	Dia Habil	19.352857
3	CPI	377.649519
4	CPI	128.340811
5	Fed Funds Rate	166.915854
6	Reservas Int	442.740635
7	Reservas Int	325.092915
8	IGBC	334.818811
9	IGBC	74.842042
10	IPC	68.639977
11	Fed Funds Rate	114.555604
12	IPC	102.970896
13	Fed Funds Rate	34.910832
14	IGBC	74.326817
15	IGBC	74.383889
16	M1 COL	56.898668
17	IGBC	75.398872
18	IGBC	74.842042

APÉNDICE C.- SENSIBILIDAD DE CADA VARIABLE DE ENTRADA

Prueba 1

Column	Input	Sensitivity
1	I: Dia Sem	0.003056

Prueba 2

Column	Input	Sensitivity
1	I: Dia Sem	0.001867
2	I: Dia Habil	0.003608

Prueba 3

Column	Input	Sensitivity
1	I: Dia Sem	0.000093
2	I: Dia Habil	0.000002
3	I: IPC	0.308932
4	I: CPI	0.986015

Prueba 4

Column	Input	Sensitivity
1	I: Dia Sem	0.012453
2	I: Dia Habil	0.342328
3	I: IPC	0.157122
4	I: CPI	0.249903
5	I: Tasa Intervencion	0.575707
6	I: Fed Funds Rate	0.158614

Prueba 5

Column	Input	Sensitivity
1	I: Dia Sem	0.721624
2	I: Dia Habil	0.640335
3	I: IPC	0.02847
4	I: CPI	0.771618
5	I: Tasa Intervencion	0.070103
6	I: Fed Funds Rate	0.109273
7	I: PIB	0.756947
8	I: GDP	0.010644

Prueba 6

Column	Input	Sensitivity
1	I: Dia Sem	0.614401
2	I: Dia Habil	0.016641
3	I: IPC	0.147172
4	I: CPI	0.801729
5	I: Tasa Intervencion	0.259018
6	I: Fed Funds Rate	0.529361
7	I: PIB	0.530306
8	I: GDP	0.07024
9	I: Reservas Int	0.844637

Prueba 7

Column	Input	Sensitivity
1	I: Dia Sem	0.000008
2	I: Dia Habil	0.000016
3	I: IPC	0.011714
4	I: CPI	0.000169
5	I: Tasa Intervencion	0.003128
6	I: Fed Funds Rate	0.00873
7	I: PIB	0.009396
8	I: GDP	0.019586
9	I: Reservas Int	0.244655
10	I: IGBC	0.009413

Prueba 8

Column	Input	Sensitivity
1	I: Dia Sem	0.001832
2	I: Dia Habil	0.008487
3	I: IPC	0.068217
4	I: CPI	0.001456
5	I: Tasa Intervencion	0.005344
6	I: Fed Funds Rate	0.069256
7	I: PIB	0.00938
8	I: GDP	0.024969
9	I: Reservas Int	0.022516
10	I: IGBC	0.731059
11	I: Monto Neg Interbancario	0.038079

Prueba 9

Column	Input	Sensitivity
1	I: Dia Sem	0.020457
2	I: Dia Habil	0.020176
3	I: IPC	0.384579
4	I: CPI	0.032043
5	I: Tasa Intervencion	0.249632
6	I: Fed Funds Rate	0.648032
7	I: PIB	0.013038
8	I: GDP	0.12088
9	I: Reservas Int	0.349922
10	I: IGBC	0.575377
11	I: Monto Neg Interbancario	0.033054
12	I: M1 COL	0.486839

Prueba 10

Column	Input	Sensitivity
1	I: Dia Sem	0.000272
2	I: Dia Habil	0.00024
3	I: IPC	0.182025
4	I: CPI	0.002616
5	I: Tasa Intervencion	0.176988
6	I: Fed Funds Rate	0.183824

Prueba 11

Column	Input	Sensitivity
1	I: Dia Sem	0
2	I: Dia Habil	0
3	I: IPC	0.969017
4	I: CPI	0
5	I: Tasa Intervencion	0
6	I: Fed Funds Rate	0.969015

Prueba 12

Column	Input	Sensitivity
1	I: Dia Sem	0.07023
2	I: Dia Habil	0.026164
3	I: IPC	0.143232
4	I: CPI	0.088391
5	I: Tasa Intervencion	0.149863
6	I: Fed Funds Rate	0.064396
7	I: PIB	0.10482
8	I: GDP	0.060263
9	I: Reservas Int	0.090867
10	I: IGBC	0.217028
11	I: Monto Neg Interbancario	0.003167
12	I: M1 COL	0.016987

Prueba 13

Column	Input	Sensitivity
1	I: Dia Sem	0
2	I: Dia Habil	0
3	I: IPC	0
4	I: CPI	0
5	I: Tasa Intervencion	0
6	I: Fed Funds Rate	0
7	I: PIB	0
8	I: GDP	0
9	I: Reservas Int	0
10	I: IGBC	0
11	I: Monto Neg Interbancario	0
12	I: M1 COL	0

Prueba 14

Column	Input	Sensitivity
1	I: Dia Sem	0.02439
2	I: Dia Habil	0.019659
3	I: IPC	0.353613
4	I: CPI	0.053476
5	I: Tasa Intervencion	0.251545
6	I: Fed Funds Rate	0.634744
7	I: PIB	0.012143
8	I: GDP	0.116568
9	I: Reservas Int	0.336491
10	I: IGBC	0.579269
11	I: Monto Neg Interbancario	0.035463
12	I: M1 COL	0.486053

Prueba 15

Column	Input	Sensitivity
1	I: Dia Sem	0.02419
2	I: Dia Habil	0.019918
3	I: IPC	0.359974
4	I: CPI	0.051042
5	I: Tasa Intervencion	0.253347
6	I: Fed Funds Rate	0.641254
7	I: PIB	0.012138
8	I: GDP	0.119421
9	I: Reservas Int	0.33989
10	I: IGBC	0.577371
11	I: Monto Neg Interbancario	0.035537
12	I: M1 COL	0.480555

Prueba 16

Column	Input	Sensitivity
1	I: Dia Sem	0.447303
2	I: Dia Habil	0.095598
3	I: IPC	0.057972
4	I: CPI	0.014298
5	I: Tasa Intervencion	0.280578
6	I: Fed Funds Rate	0.602538
7	I: PIB	0.166951
8	I: GDP	0.063702
9	I: Reservas Int	0.404149
10	I: IGBC	0.842199
11	I: Monto Neg Interbancario	0.418948
12	I: M1 COL	0.512389

Prueba 17

Column	Input	Sensitivity
1	I: Dia Sem	0.375464
2	I: Dia Habil	0.064051
3	I: IPC	0.423865
4	I: CPI	0.340359
5	I: Tasa Intervencion	0.041705
6	I: Fed Funds Rate	0.476605
7	I: PIB	0.131487
8	I: GDP	0.089968
9	I: Reservas Int	0.378955
10	I: IGBC	0.760792
11	I: Monto Neg Interbancario	0.186363
12	I: M1 COL	0.706591

Prueba 18

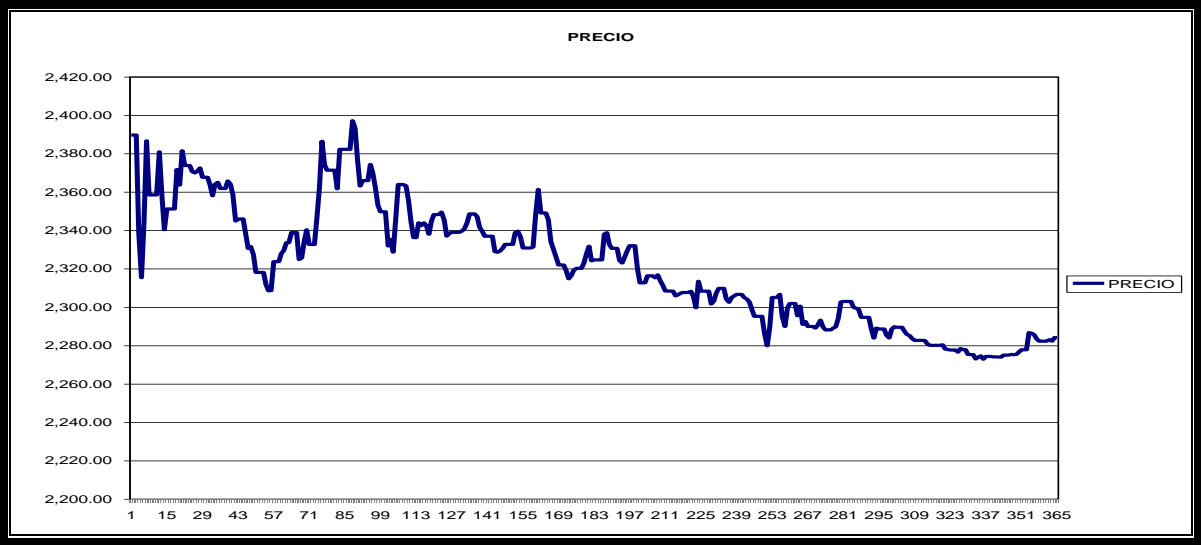
Column	Input	Sensitivity
1	I: Dia Sem	0.020457
2	I: Dia Habil	0.020176
3	I: IPC	0.384579
4	I: CPI	0.032043
5	I: Tasa Intervencion	0.249632
6	I: Fed Funds Rate	0.648032
7	I: PIB	0.013038
8	I: GDP	0.12088
9	I: Reservas Int	0.349922
10	I: IGBC	0.575377
11	I: Monto Neg Interbancario	0.033054
12	I: M1 COL	0.486839

Resumen

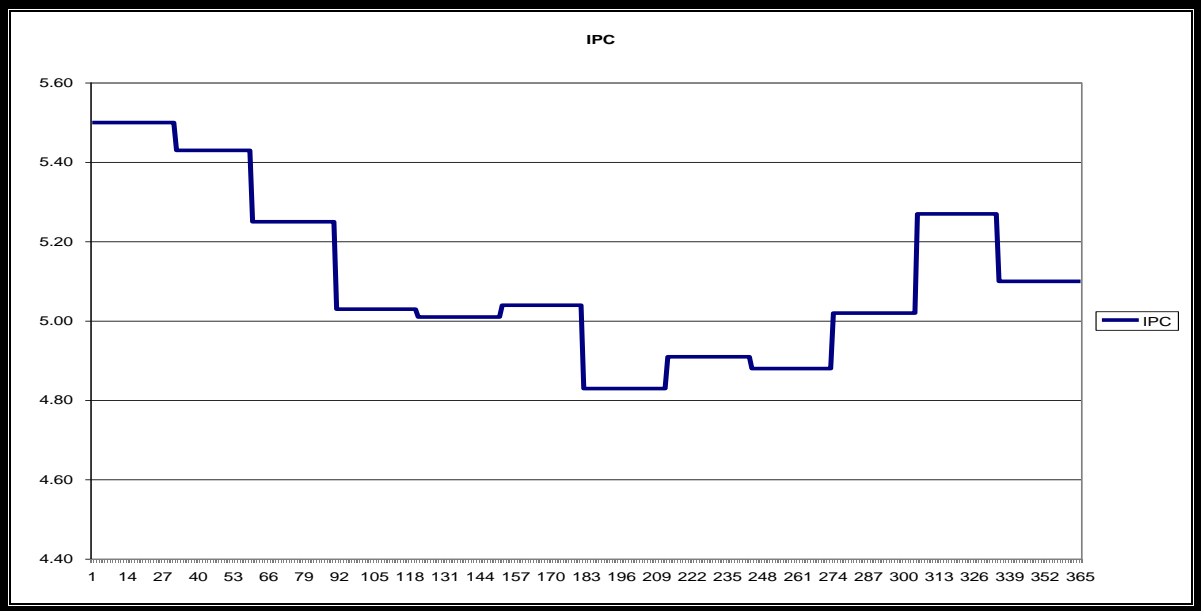
Prueba	Input	Sensitivity
1	I: Dia Sem	0.003056
2	I: Dia Habil	0.003608
3	I: CPI	0.986015
4	I: Tasa Intervencion	0.575707
5	I: CPI	0.771618
6	I: Reservas Int	0.844637
7	I: Reservas Int	0.244655
8	I: IGBC	0.731059
9	I: Fed Funds Rate	0.648032
10	I: Fed Funds Rate	0.183824
11	I: IPC	0.969017
12	I: IGBC	0.217028
13	No Aplica	0
14	I: Fed Funds Rate	0.634744
15	I: Fed Funds Rate	0.641254
16	I: IGBC	0.842199
17	I: IGBC	0.760792
18	I: Fed Funds Rate	0.648032

APÉNDICE D.- VARIABLES DE LA RED NEURONAL ARTIFICIAL


Precios de Cierre




IPC



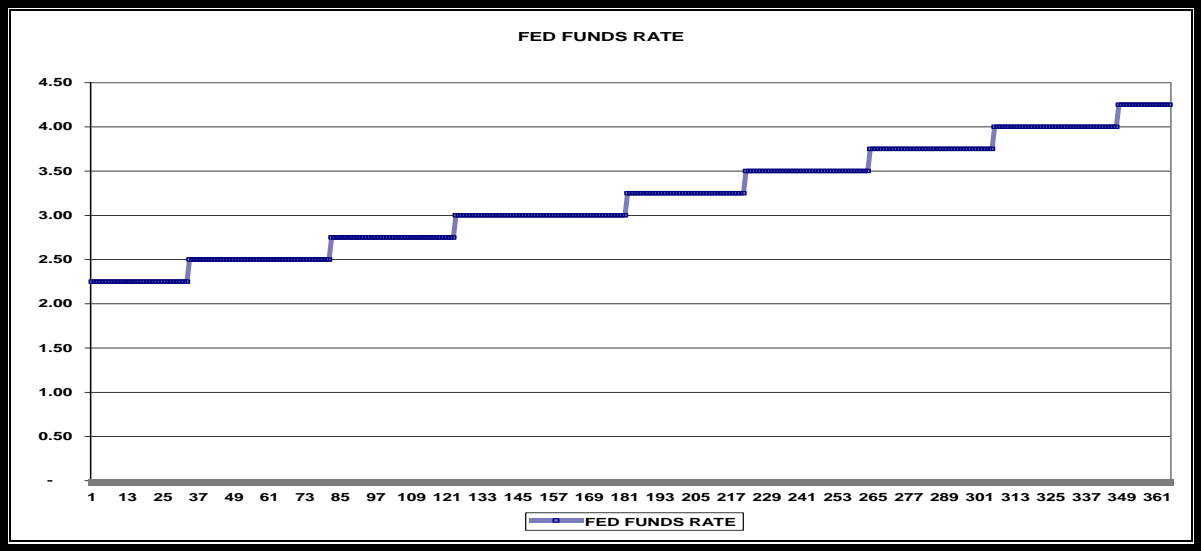
CPI



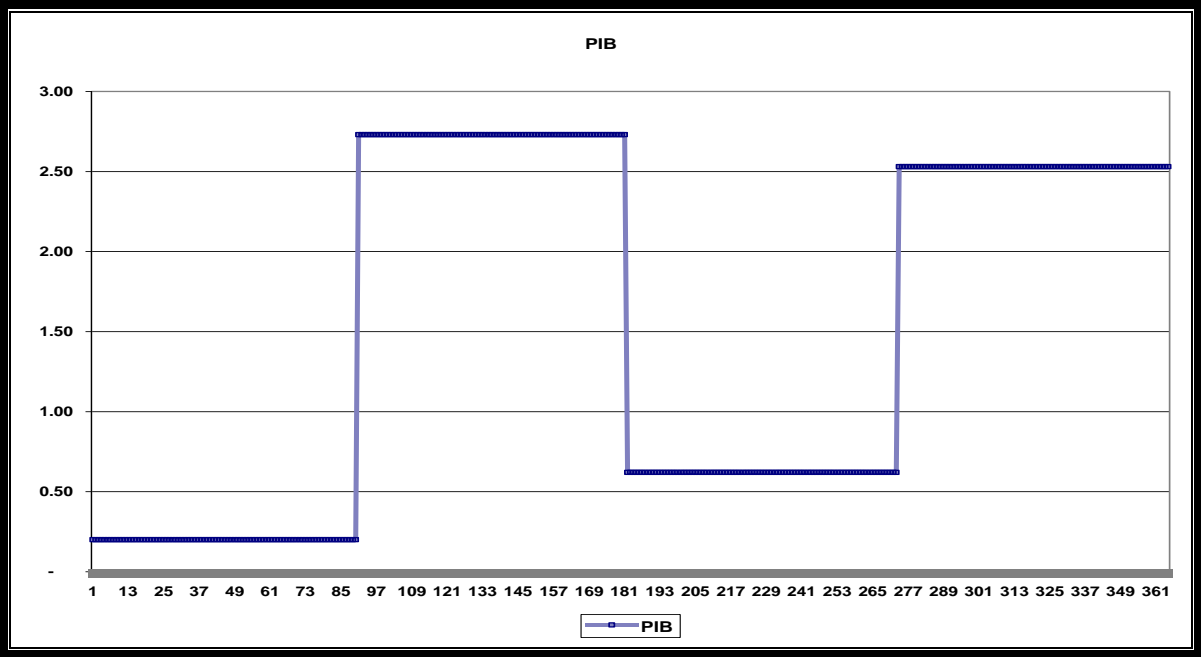
TASA DE INTERVENCIÓN



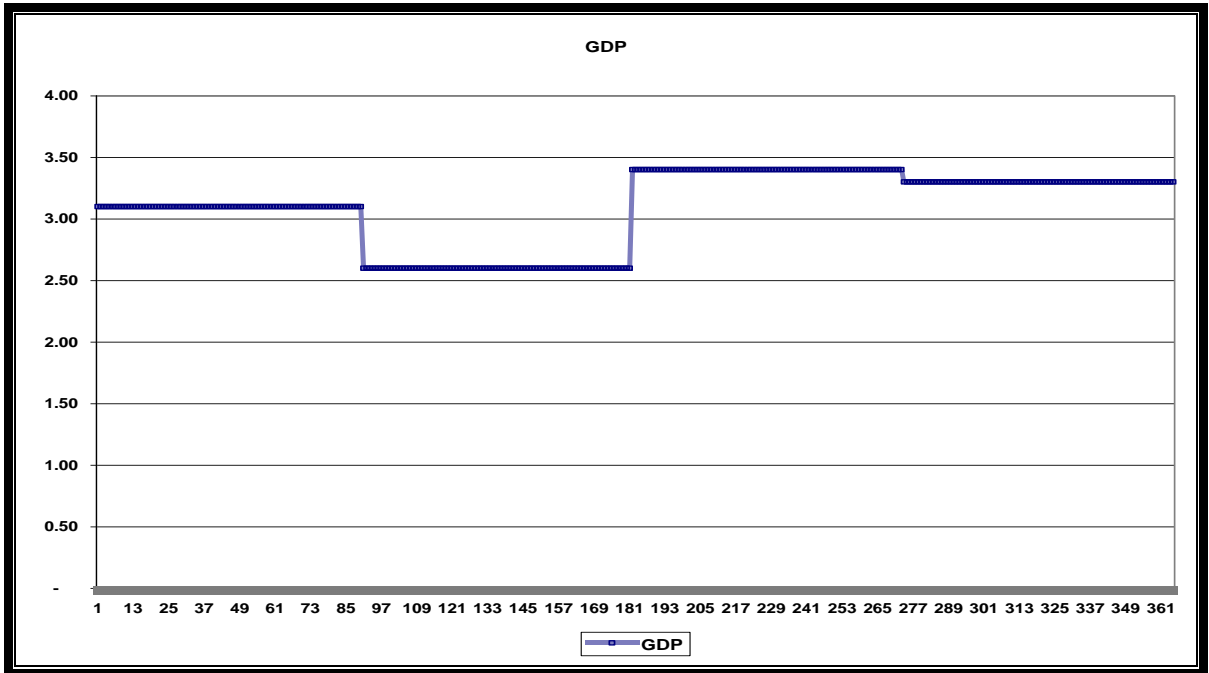
FED FUNDS RATE




PIB



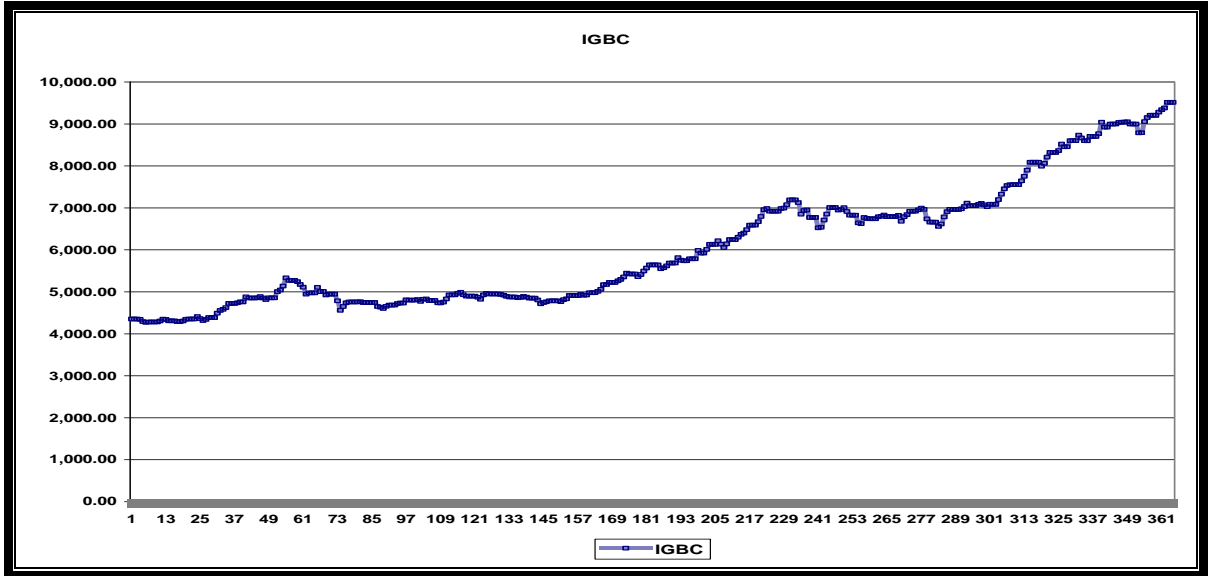
GDP



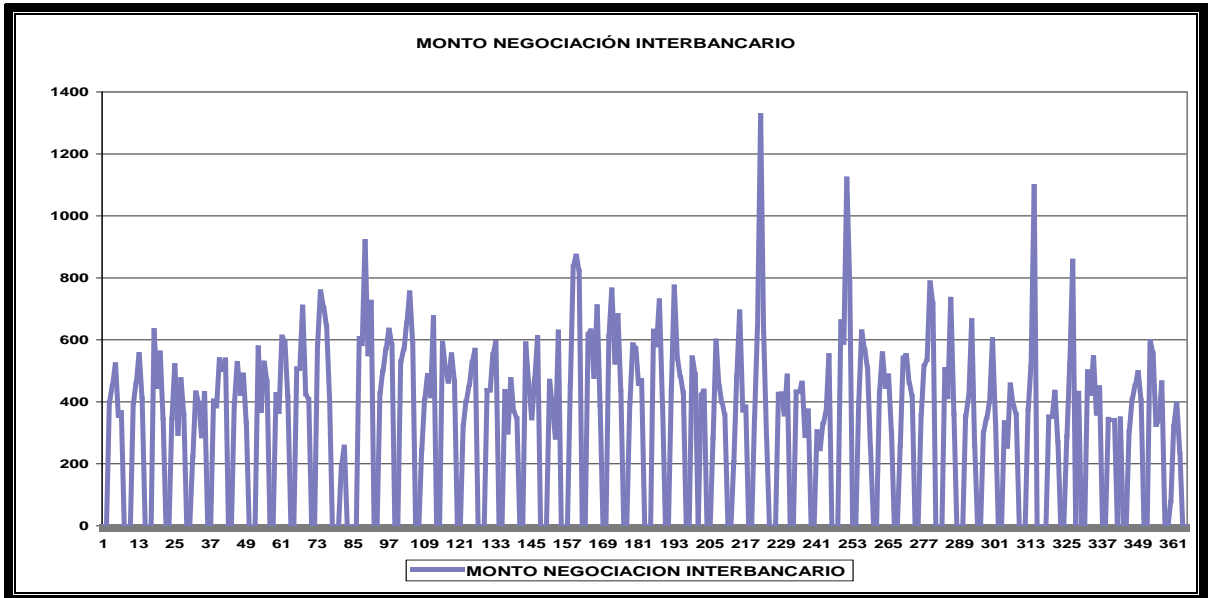
RESERVAS INTERNACIONALES



IGBC



MONTO DE NEGOCIACIÓN INTERBANCARIO



AGREGADO MONETARIO M1 EN COLOMBIA

