

**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**  
**FACULTAD DE ARQUITECTURA**  
**CENTRO DE INVESTIGACIONES Y ESTUDIOS DE POSGRADO**  
**ESPECIALIDAD EN VALUACIÓN INMOBILIARIA**



# **APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN LA VALUACIÓN INMOBILIARIA**

**TESINA DE ESPECIALIZACIÓN**

PARA OBTENER EL TÍTULO DE ESPECIALISTA EN:

**VALUACIÓN INMOBILIARIA**

PRESENTA:

**ARQ. AGNIESZKA KOZLOWSKA**

**MÉXICO D.F. 2008**



Universidad Nacional  
Autónoma de México



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

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

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

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

## **AGRADECIMIENTOS.**

A mi Alma Mater, por permitirme ser parte de la Comunidad Universitaria, un motivo de orgullo en mi vida.

Mi más sincero agradecimiento al EVI. Arq. Alfonso Luis Penela Quintanilla, por su apoyo profesional y disponibilidad, por impulsarme en el campo de la valuación inmobiliaria y apoyarme incondicionalmente en la realización del presente trabajo.

Al EVI. Ing. Juan Antonio Gómez Velázquez, por sus interesantes clases, llenas de valiosas aportaciones, por su generosidad y apoyo, gracias.

Al EVI. Ing. Manuel García Córdova, por su compromiso académico, amistad y disponibilidad, mi más sincero agradecimiento.

Al EVI. Arq. Daniel J. Silva Troop, por compartir sus conocimientos de valuación y experiencias profesionales, así como por su disponibilidad, mi más profundo agradecimiento.

Al Dr. Ángel Fernando Kuri Morales, por su generosidad, paciencia, disponibilidad y asesoría profesional, mi más sincero cariño.

A todos mis profesores y asesores, que a lo largo de la especialidad han contribuido a mi formación profesional, compartiendo generosamente sus conocimientos, mi más profundo agradecimiento.

A mi esposo Edgar, por su amor, paciencia, valiosos consejos y por todos los sacrificios que ha implicado la realización de este sueño. Eres la persona más importante de mi vida.

*Nieskonczona wdziecznosc wyrazam mojemu mezowi Edgarowi, za jego milosc, cierpliwosc, rady i poswiecenie, jakiego wymagalo spelnienie tego marzenia. Jestes najwazniejsza osoba w moim zyciu.*

A mis padres Krystyna e Ireneusz, por su amor, comprensión y apoyo incondicional a las mayores decisiones de mi vida.

*Moim rodzicom, Krystynie i Ireneuszowi, za ich milosc, zrozumienie i wsparcie w podejmowaniu zyciowych decyzji.*

A mis suegros, Dulce María Bazán Ureste y Sergio Lamadrid Alcalá, por hacerme sentir parte de la familia, por su apoyo y cariño.

*Moim tesciom, Dulce María Bazán Ureste y Sergio Lamadrid Alcalá, za cieple przyjecie mnie do grona rodzinnego i za troske.*

## ÍNDICE

### INTRODUCCIÓN

CAPÍTULO I.....	1
- EL CEREBRO Y LAS COMPUTADORAS.....	1
- FUNCIONAMIENTO Y ESTRUCTURA DE UNA NEURONA BIOLÓGICA....	3
- LA INTERACCIÓN ENTRE NEURONAS BIOLÓGICAS.....	5
CAPÍTULO II.....	8
- EL MODELO DE UNA NEURONA ARTIFICIAL.....	8
- EL MODELO DE UNA RED NEURONAL ARTIFICIAL.....	9
- EL ENTRENAMIENTO O EL PROCESO DE APRENDIZAJE DE LA RED..	16
CAPÍTULO III.....	21
- APLICACIÓN DE LAS RNA.....	21
- APLICACIÓN DE LAS RNA EN LA VALUACIÓN INMOBILIARIA.....	21
CAPÍTULO IV.....	27
- CASO PRÁCTICO DE ESTUDIO DETERMINACIÓN DE LOS VALORES DE LOS DEPARTAMENTOS EN LA DELEGACIÓN BENITO JUAREZ, MÉXICO D.F.....	27
- PROBLEMA.....	27
- BASE DE DATOS.....	27
- PREPROCESAMIENTO DE DATOS.....	38
- ARQUITECTURA DE LA RED.....	47
- PRUEBA.....	52
CONCLUSIONES.....	54
BIBLIOGRAFÍA.....	57

## INTRODUCCIÓN

El método de mercado ha sido por muchos años y sigue siendo “el método” más común del valuador para determinar el valor de un inmueble. Este enfoque tiene sus bases en el siguiente principio: “inmuebles similares se comercializan a precios similares” y consiste en la búsqueda de una muestra de inmuebles “comparables”, es decir similares en sus características (cuantitativas y cualitativas) al inmueble objeto del avalúo. Dado que se trata de inmuebles similares pero no idénticos en sus características (variables cualitativas y cuantitativas), el valuador está obligado recurrir al proceso de corrección u homologación de los comparables encontrados, a veces mediante expresiones lógico – matemáticas más o menos acertadas, y a veces simplemente recurriendo a calificativos empíricos (casi igual, mejor, mucho mejor, francamente mejor, un poco peor, peor, mucho peor, francamente peor, etc.) traducidos por el mismo valuador a números (normalmente porcentajes), sobre todo cuando se trata de las variables cualitativas. Todo esto, con la finalidad de “acercar” lo más posible todos los comparables seleccionados a su objeto del avalúo.

El problema o la deficiencia de esta metodología consisten en el alto nivel de subjetividad que la caracteriza a la hora de que los valuadores emplean sus “criterios” de homologación aplicando diferentes factores de corrección a una serie de variables sobre todo si estas son cualitativas (no expresadas por valores numéricos). Finalmente una gran mayoría de los valuadores ni siquiera se preocupa por verificar, si después de haber realizado el proceso de “homologación”, según sus criterios, los comparables se homologaron realmente, es decir que los factores aplicados a sus variables los acercaron en términos matemáticos entre sí y al inmueble objeto del avalúo.

No cabe duda que la subjetividad presente a la hora de realizar el método de mercado afecta la exactitud del cálculo del valor del bien inmueble.

Al inicio de los 80, la masiva accesibilidad a las computadoras que contenían los paquetes estadísticos coincidió con el primer intento de perfeccionar la metodología de mercado consistente en las técnicas de regresión múltiple. Esta herramienta, permitía que los referenciales fueran capaces de autocorregirse, eliminando la subjetividad del criterio del valuador.

Si bien la regresión múltiple trata de eliminar la subjetividad del valuador, este método tiene un defecto: trabaja con base en modelos matemáticos rígidos y procesa inexactamente las variables cualitativas.

Otro intento de eliminar la subjetividad del proceso de valuación son los métodos de valuación multicriterio y en particular Proceso Jerárquico Analítico AHP (Analytic Hierarchy Process). Si bien los métodos multicriterio “afinan” la capacidad de definir y calificar las variables cualitativas, haciendo que el valuador tiene que realizar las comparaciones pareadas de dos elementos en función de

una característica determinada, esto con base en el estudio de Miller<sup>1</sup>, son rígidos en asignar a cada gradiente de calificativos un valor numérico a priori. Hacen esto utilizando una escala lineal de valores cuyos rangos pueden variar entre 0-10 y 0-100, siendo la primera la más utilizada en la valuación de inmuebles. Además de la limitante de calificar con base en gradiente rígida de calificativos ascendentes o descendentes, los métodos multicriterio, para realizar el proceso de valuación, utilizan los mismos rígidos modelos matemáticos que la regresión múltiple.

El galopante desarrollo tecnológico de las últimas décadas ha abierto las puertas de diversas áreas del conocimiento humano a la aplicación de la inteligencia artificial (imitación del funcionamiento del cerebro), donde las Redes Neuronales Artificiales (RNA) han suscitado un interés particular debido a su capacidad de representar problemas no lineales por medio de entrenamiento, aprendizaje y su capacidad de generalización.

El origen y el fundamento de las RNA se encuentran, como indica su propio nombre, en la simulación más o menos precisa del funcionamiento de las neuronas del cerebro humano. Estas nuevas formas de computación tienen por objetivo fundamental la solución de todos aquellos problemas, en los que el nivel de incertidumbre y/o imprecisión que se presenta (reconocimiento de la forma, de la voz, la toma de decisiones, etc.) impide que puedan ser abordados desde un enfoque estrictamente algorítmico.

El presente trabajo tiene por objetivo presentar un sistema alternativo de valuación de inmuebles basado en la inteligencia artificial y concretamente en la RNA tipo PERCEPTRON MULTICAPA.

El objetivo del trabajo es realizar un ejemplo de su aplicación para poder determinar las ventajas y desventajas de esta herramienta, así como los campos de aplicación de la misma en la valuación inmobiliaria.

En el primer capítulo se habla del funcionamiento y de las capacidades del cerebro humano y de las computadoras haciendo el énfasis en las diferencias entre ambos sistemas. Posteriormente se hace una resumida descripción de una neurona biológica así como la interacción entre células nerviosas, esto con la finalidad de poder entender mejor el funcionamiento de las RNA.

El segundo capítulo empieza con la descripción de los principales elementos de la estructura y del funcionamiento de una neurona artificial para posteriormente describir algunas características de la RNA multicapa y sus aplicaciones. El capítulo termina con algunos datos relativos al entrenamiento de las RNA. Cabe señalar que el objetivo de este trabajo no es la descripción

---

<sup>1</sup> Miller demostró en 1956 que el cerebro humano tiene serias limitaciones para realizar comparaciones entre distintos sujetos o alternativas si su número es superior a 7.

exhaustiva de la estructura y del funcionamiento de las RNA, dado que su creación pertenece al campo de la informática y de las matemáticas aplicadas y no al de la valuación inmobiliaria. Por lo tanto, toda la información contenida es enunciativa y sumamente resumida tratando de evitar la introducción de complejas fórmulas matemáticas que acompañan el diseño y funcionamiento de una RNA.

El tercer capítulo inicia mencionando algunas aplicaciones de las RNA en diferentes campos de la actividad humana, para posteriormente concentrarse en el uso que hasta ahora han tenido las RNA en el campo de la valuación inmobiliaria.

Este capítulo contiene un resumen de los trabajos más relevantes realizados por diferentes valuadores en varios países.

El cuarto capítulo se concentra en la aplicación práctica de la RNA DATAENGINE en la valuación de los inmuebles habitacionales en la Ciudad de México, concretamente departamentos nuevos y usados de la Delegación Benito Juárez, teniendo a disposición una base de datos de 143 inmuebles, de los cuales 112 se destinarán al entrenamiento de la red, mientras que los 31 restantes servirán como test de prueba de la capacidad de respuesta de la red entrenada. La base de datos proviene de la Unidad de Valuación CMV S.A. de C.V. (Corporación Mexicana de Valuación S.A. de C.V.) y su utilización fue autorizada por el director de la misma E.V.I. Arq. Alfonso Luis Penela Quintanilla.

El trabajo finaliza con las conclusiones y con la bibliografía consultada.

## CAPÍTULO I

### EL CEREBRO Y LAS COMPUTADORAS

La neurocomputación o la computación análoga al cerebro humano constituyen un intento de desarrollar software que se inspiran o tratan de imitar el funcionamiento del cerebro humano. Esta rama de la informática pudo desarrollarse gracias a los avances de la medicina y de la tecnología, en particular al invento del aparato de escaneo corporal llamado tomógrafo que permite conocer y analizar algunos procesos cerebrales imposibles de visualizar anteriormente.

La computadora y el cerebro guardan cierta analogía: capturan datos del exterior, los guardan en su memoria para posteriormente realizar procesos internos para obtener resultados demandados. Ambos sistemas deben enfrentar problemas similares cuales: asociación, clasificación, categorización, generalización, respuesta rápida, inferencia ágil a partir de datos disponibles, etc.

Sin embargo cualquier computadora es capaz de realizar complejos cálculos de manera más rápida y precisa que el ser humano, mientras que falla a la hora de realizar procesos de enorme sencillez para éste, como el reconocimiento de un sonido, de una imagen, la intuición, la realización de buenas suposiciones, etc.

Se estima que la velocidad de la transmisión de datos en el cerebro humano es un millón de veces más lenta que el de una computadora.

Al inicio de la era informática, cuando las primeras computadoras realizaban las tareas “sencillas”<sup>1</sup>, se creía que con el avance de la programación, éstas iban a ser capaces de hacer de todo.

Sin embargo las tareas sencillas para el cerebro humano (reconocimiento de caras, imitación de la forma de moverse de las personas) no pueden ser resueltas

---

<sup>1</sup> Las primeras computadoras digitales surgieron debido a la necesidad de hacer frente a un problema práctico bien definido: COLOSSUS fue producida por los británicos durante la Segunda Guerra Mundial para aplicaciones criptográficas respondiendo a la necesidad de transmitir las instrucciones desde los cuarteles generales hasta el campo de batalla sin que el enemigo pudiera entenderlas incluso después de haber interceptado el mensaje, mientras que ENIAC fue desarrollada por los científicos de la Escuela Moore de Ingeniería (Universidad de Pennsylvania) para calcular las tablas balísticas de disparo utilizadas por el ejército de Estados Unidos de América. La computadora ENIAC, con la técnica desarrollada para resolver un problema específico, resultó tener una aplicación más general convirtiéndose en la predecesora de la industria moderna de la computación.

por una máquina aun más sofisticada. En el caso del movimiento, el de un robot es mucho más torpe y rígido que el de una persona, y esto se debe no solo a la complejidad de la estructura de una pierna o un brazo (una grúa sofisticada posee menos de 10 articulaciones, mientras que un brazo más de 40), si no, que la computadora que controla el movimiento no es capaz de procesar la gran cantidad de datos cambiantes a cada paso que permiten mantener el equilibrio.

Lo mismo pasa con el reconocimiento de las personas: mientras que nuestro cerebro es capaz de reconocer el rostro una persona que no hemos visto en años, procesando en cuestión de segundos un patrón de información tridimensional, la computadora más sofisticada se tarda días en hacerlo. Además el cerebro, a diferencia de la computadora, el cerebro es capaz de responder correctamente a un estímulo nunca antes recibido: al presentarnos por primera vez una persona, sabemos automáticamente que es un ser humano y no un objeto o un animal, mientras que una computadora no es capaz de hacer esta clasificación.

Esto demuestra que la estructura y el funcionamiento de la computadora y del cerebro difieren. Los microprocesadores de la computadora son conectados entre sí “en serie”, son de tipo secuencial, es decir realizan una sola operación a la vez, pero a gran velocidad, mientras que, las neuronas están conectadas entre sí “en paralelo”, en forma masiva, compleja, no lineal, en capas.

Esto quiere decir, que en el cerebro humano<sup>2</sup> a la hora de la realización de las actividades arriba mencionadas, millones de neuronas procesan la información de manera simultánea, mostrándose capaces de manejar y resolver todo el conjunto de imprecisiones, errores e incertidumbres que se plantean en el mundo, real sin afectar excesivamente los resultados. Esto demuestra que el cerebro se caracteriza por una gran plasticidad, y a pesar que sea considerablemente más lento que las computadoras, escapa a la rigidez que, en la mayoría de los casos, caracteriza a un algoritmo, que constituye la base de la programación de las computadoras.

El cerebro humano compensa su lentitud con la cantidad de las neuronas y su capacidad de trabajo simultáneo.

---

<sup>2</sup> La ciencia ha demostrado que el sistema nervioso humano es casi idéntico al de los otros vertebrados: 99% de nuestro ADN es idéntico al de un chimpancé. El restante 1% constituyen los genes estructurales responsables por la modificación de la forma y del tamaño de las estructuras. Lo que distingue entonces a nuestro cerebro del de los otros animales es la capacidad de *sintonización fina*.

La ciencia cree que las neuronas o células nerviosas son las unidades básicas utilizadas para la computación en el sistema nervioso biológico (el cerebro). El ser humano posee entre  $10^{10}$  (cien mil millones) y  $10^{11}$  (un millón de millones) neuronas conectadas entre sí en capas, todas capaces de cooperar simultáneamente, mientras que el número de procesadores de una computadora es muy limitado, en las más sofisticadas no alcanzan un millón. A su vez cada neurona tiene cientos o hasta miles de conexiones con otras neuronas, ascendiendo el número total de conexiones en el cerebro a  $10^{14}$  o  $10^{15}$ . Cabe señalar que una neurona se conecta directamente tan solo con un pequeño número de neuronas y aún así la eficiencia energética del cerebro es  $10^{10}$  (cien mil millones) veces mayor que la de las mejores computadoras.

La estructura del cerebro humano está diseñada para aprender. La capacidad de aprendizaje es la que lo hace diferente de las computadoras que son programadas. La programación de una computadora, aún la más sofisticada es fija, mientras que el cerebro es capaz de cambiar su proceso interno cuando corrige los errores cometidos reduciéndolos al mínimo; el cerebro ajusta continuamente sus procesos mediante el sistema de prueba y error. Este sistema de aprendizaje del cerebro lo hace adaptable a la cambiante situación externa.

## **FUNCIONAMIENTO Y ESTRUCTURA DE UNA NEURONA BIOLÓGICA**

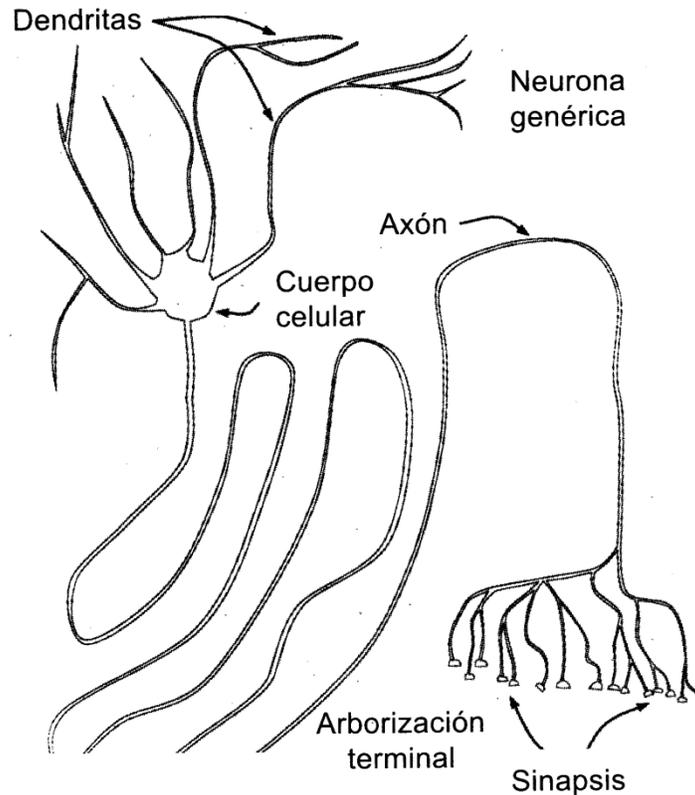
La neurona biológica es una estructura sumamente compleja y no es objetivo de este trabajo analizarla en todos los detalles, sin embargo se considera necesario exponer la información más relevante acerca de la misma para poder entender mejor el funcionamiento de las RNA.

Como ya se ha mencionado el ser humano posee entre  $10^{10}$  y  $10^{11}$  neuronas conectadas entre sí en capas, mientras que el número total de conexiones se estima ascienden a  $10^{14}$  o  $10^{15}$ .

Todo el espacio del cerebro que no está ocupado por las neuronas, lo llenan las células gliales o neuroglías, cuya función es dar soporte metabólico y físico a las neuronas. Dado que las neuronas son muy sensibles mecánicamente, el cerebro está encerrado en un cráneo duro y para evitar que las neuronas se dañen por el contacto con el hueso, el cerebro flota en el fluido cerebroespinal que tiene la función de suspensión hidráulica.

Otra característica de las neuronas es su alta actividad metabólica: el sistema nervioso humano consume 25% de la energía que utiliza el cuerpo, constituyendo solo 1 o 2% del peso total del cuerpo. Los mamíferos no producen ninguna neurona después de nacidos, cuando una neurona muere no se reemplaza, además de que la investigación médica ha demostrado que un considerable número de neuronas muere inclusive antes del nacimiento.

La neurona genérica está modelada con base en las neuronas motoras o motoneuronas espinales, que son las más conocidas entre todas las neuronas hasta ahora. Siendo células, las neuronas tienen un núcleo y el aparato metabólico celular relacionado.



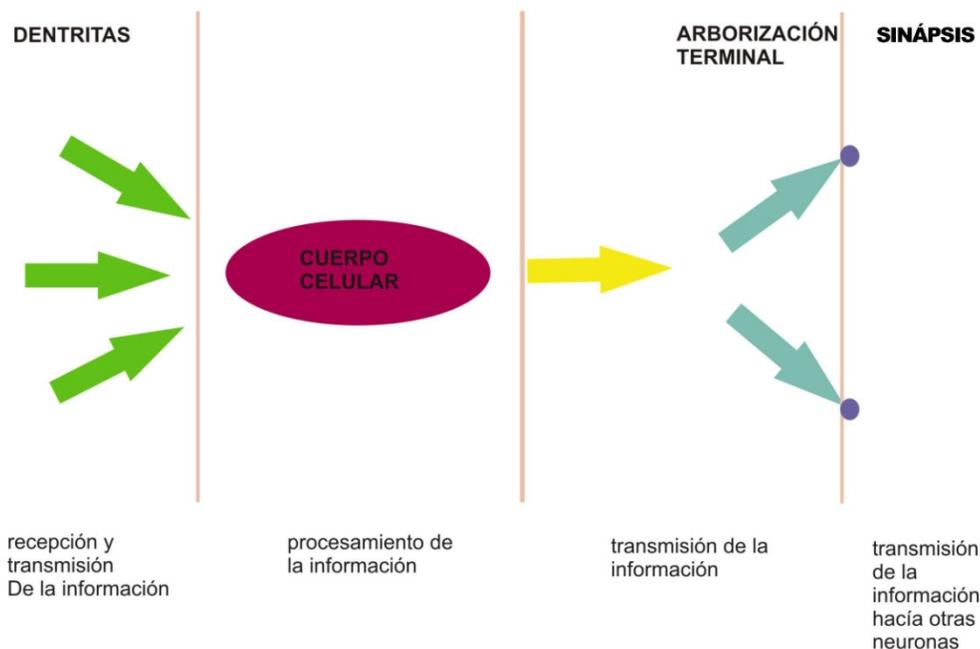
### NEURONA GENÉRICA

El cuerpo de una neurona se compone de las siguientes partes:

- **DENDRITAS** (del griego *dendro-*, árbol) – son finas ramificaciones que constituyen la entrada hacia la neurona desde otras células; su función es la de la recepción de la información y su transmisión hacia el soma
- **SOMA** – cuerpo celular, su función es procesar e integrar la información
- **AXÓN** – larga y delgada ramificación que se aparta del cuerpo celular y se puede extender por metros (las motoneuronas espinales en la parte baja de la espalda pueden tener axones que llegan hasta los dedos de los pies); constituye la línea de transmisión de la neurona, junto a la

rama principal puede tener ramificaciones colaterales, su función es la de transmitir la información hacia las sinápsis

- ARBORIZACIÓN TERMINAL (del latín *arbor* -, árbol) - la ramificación final del axón
- SINÁPSIS – estructuras en los extremos de la ramificación final del axón, su función es la de proporcionar entradas a otras neuronas u órganos efectores. La sinápsis permite que una célula influya en la actividad de las otras. Las detalladas interacciones entre muchas neuronas son la clave de la naturaleza de los cómputos que realizan las redes neurales.
- NÚCLEO – tiene el trabajo de enviar nutrientes, enzimas y materiales de construcción por el axón hacia el resto de la célula; también existe el flujo retrógrado de los materiales de regreso hacia el núcleo.



## LA INTERACCIÓN ENTRE NEURONAS BIOLÓGICAS

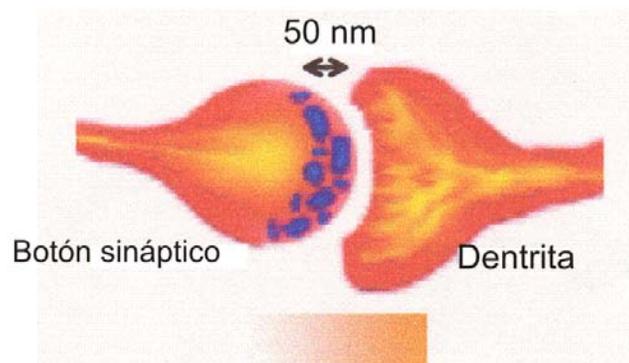
Cada neurona está cubierta por su propia membrana separada de las otras, cuya función consiste en separar el interior del exterior y cuyas propiedades

químicas influyen en la transmisión de la información. Como ya se ha mencionado la información de una neurona a otra fluye a través de las sinápsis que para su funcionamiento utilizan varias estructuras especializadas así como las moléculas llamadas neurotransmisores.

El comportamiento de una neurona es el siguiente: recibe una señal de entrada con una fuerza determinada, dependiendo de la fuerza de la señal la neurona emite una señal de respuesta. Las sinápsis pueden variar en fuerza, algunas pueden dar una señal débil, otras una señal fuerte. A una neurona pueden llegar miles de señales de entrada, cada una con una fuerza o peso diferente. La representación matemática del comportamiento de una neurona es una lista de sus señales de entrada que son multiplicados por sus pesos respectivos y posteriormente sumados. El resultado es llamado el nivel de activación de la neurona, del cual depende la señal de salida que es enviada a cada una de las neuronas a las que está conectada a ella.

La mayoría de las neuronas codifican sus salidas como breves pulsos periódicos, llamados *potenciales de acción*. Éstas se originan cerca del soma (cuerpo celular) y se propagan por el axón hasta arborización terminal para finalmente alcanzar las sinápsis por medio de las cuales se conectarán con las dendritas de la neurona siguiente.

Una unión sináptica tiene dos lados: el de la entrada o presináptico (botón sináptico de la neurona generadora) y el de la célula receptora o postsináptico (dendrita de la neurona receptora).



#### SALTO SINÁPTICO

Existen dos tipos de sinápsis: eléctrica y química.

La sinapsis eléctrica se produce por el flujo directo de la corriente desde la neurona presináptica a la postsináptica. Es el modo más rápido de comunicación entre las neuronas.

La sinapsis química: es la más lenta que la eléctrica, porque la neurona presináptica libera el neuro transmisor que pasa a difundirse por la hendidura sináptica y se une después a los receptores de la membrana celular postsináptica.

Su funcionamiento es el siguiente: la señal eléctrica pre-sináptica llega al botón sináptico y rompe las vesículas sinápticas (azul), que liberan la sustancia llamada neurotransmisor. El neurotransmisor se difunde en el espacio entre las neuronas y es captado por la dentrita, donde estimula la emisión de nuevo impulso eléctrico post-sináptico que es propagado hacia cuerpo celular de la neurona que lo recibió. Esto sugiere que la neurona se está comportando como un convertidor de voltaje a frecuencia, que no es otra cosa que una clase de codificación, que en el sistema nervioso es conocido como codificación por frecuencia.

Cabe señalar que el impulso que llega a una sinápsis y el que sale de ella no son iguales. El tipo de impulso que sale depende de la cantidad de neurotransmisor, que cambia durante el proceso de aprendizaje. Esto quiere decir que una sinápsis modifica el pulso ya sea debilitándolo o reforzándolo.

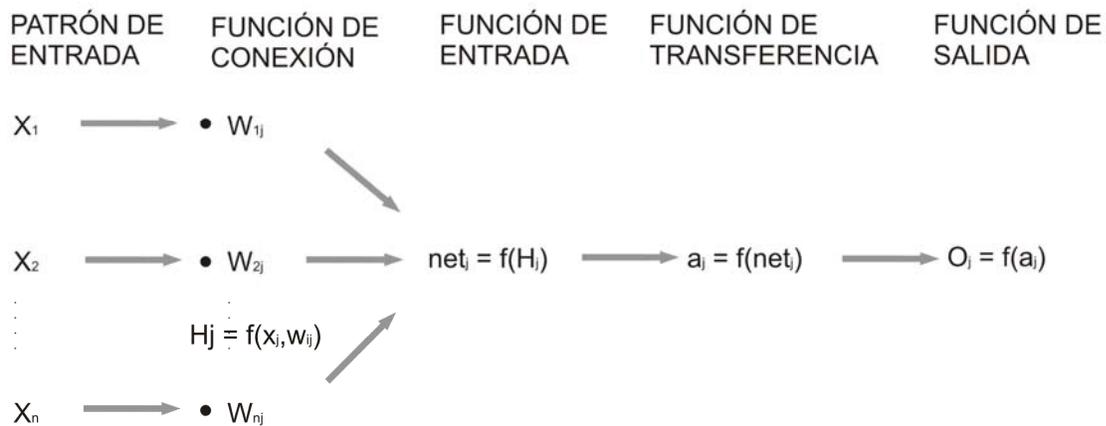
En el soma desembocan todas las Dentritas, si la suma de las señales recibidas por todas las dentritas sobrepasa un cierto umbral, entonces se transmitirá un pulso a través del axón, en el caso contrario no se transmitirá. Después de transmitir un impulso, la neurona no puede transmitir durante un lapso entre 0.5 y 2 ms. A este tiempo se le llama periodo refractario.

**EL MODELO DE UNA NEURONA ARTIFICIAL**

Como ya se ha mencionado en la introducción del presente trabajo, no es propósito del mismo describir y explicar ni la historia de las RNA ni su diseño y construcción dado que su creación pertenece al campo de la informática y de las matemáticas aplicadas y no al de la valuación inmobiliaria. Por lo tanto, toda la información contenida es enunciativa, resumida, utiliza lenguaje sencillo y trata de evitar la introducción de complejas fórmulas matemáticas que acompañan el diseño de una RNA.

La unidad básica de una RNA, al igual que de un cerebro, es una neurona. El modelo básico de una neurona para construir una RNA es el siguiente:

**PROCESO DE INFORMACIÓN NEURONAL**



Cada neurona se caracteriza por cuatro componentes:

- La función de conexión
- La función de entrada (input)
- La función de activación o de transferencia
- La función de salida (output)

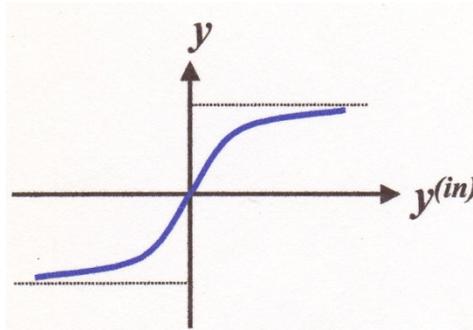
Una neurona recibe señales vía varias conexiones de entrada. La función de conexión determina el peso de cada una de las señales en la entrada de la neurona. Estos pesos definen la fuerza de acoplamiento (sinapsis) de las respectivas conexiones y se determinan por medio de proceso de aprendizaje, en el transcurso del cual vienen modificados de acuerdo a los patrones y reglas de aprendizaje.

La función de entrada comprime estas señales de entrada y sus pesos respectivos en un valor escalar (numérico, magnitud física que carece de dirección), conocido también como actividad de red de esta neurona. Para esto se emplea la suma. En este caso, la actividad de red, la cual resulta de la función de conexión y de la función de entrada, es la suma del producto de los valores de entrada y sus respectivos pesos. La función de activación o de transferencia determina un nuevo estatus de activación con base en la actividad actual de la red y tomando en cuenta el estatus previo de la neurona.

Este nuevo estatus de activación se transmite hacia la estructura de conexión de la red vía la función de salida (output) de la neurona, la cual normalmente es una función lineal. Como analogía con la neurona biológica, el estatus de activación en la salida de la neurona es también conocido como la excitación de la neurona.

Existen diferentes tipos de funciones de activación y su empleo depende de las reglas de aprendizaje. La regla de aprendizaje "backpropagation", requiere de una función derivable como lo es la sigmoidea, que además tiene la ventaja que su derivada puede ser expresada usando la misma función sigmoidea.

$$f(z) = 1 / (1 + e^{-z}) \quad f'(z) = f(z) * (1 - f(z))$$



**GRÁFICA DE LA FUNCIÓN SIGMOIDEA**

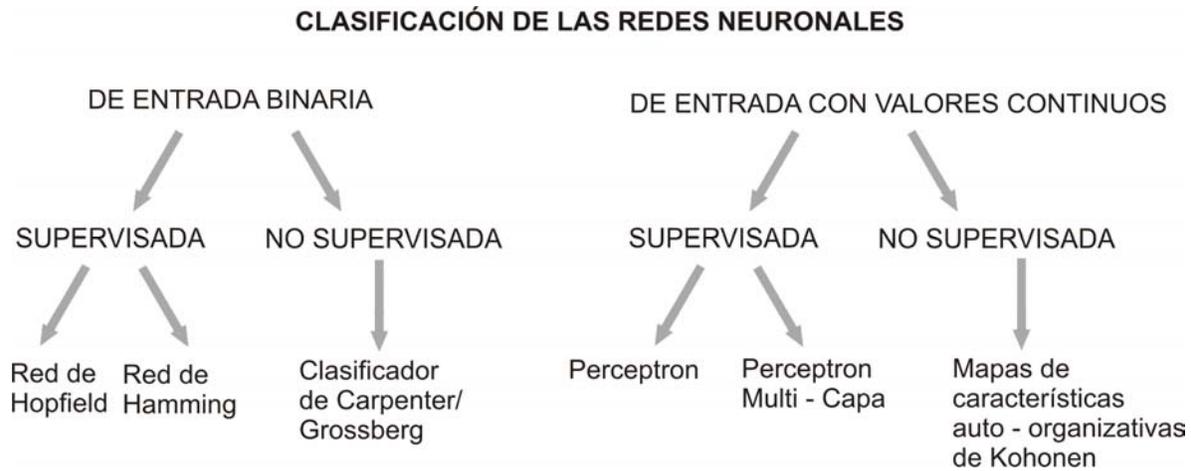
Es necesario que la función de activación sea derivable para poder igualarla a 0 y encontrar el mínimo, que es el valor donde el error sea el mínimo.

### **EL MODELO DE UNA RED NEURONAL ARTIFICIAL**

Una red neural o neuronal es un procesador de información y de distribución de tipo paralelo, constituido por muchas unidades sencillas de procesamiento llamadas neuronas. Las principales características de las RNA son:

- No son algorítmicas como lo es la Regresión Múltiple, es decir que no se programan obligándoles a seguir una secuencia predefinida de instrucciones. Las RNA generan ellas mismas sus propias "reglas", para asociar una respuesta a sus entradas. Las RNA aprenden de sus propios errores.
- Son capaces de adquirir el conocimiento a través de aprendizaje; por lo tanto son un sistema adoptivo; el conocimiento es almacenado, al igual que en el cerebro, en el peso relativo de las conexiones interneuronales. Una red neural biológica tiene que enfrentar todos los problemas al mismo tiempo. Para que la red neural artificial lo haga necesita del entrenamiento, consistente en el conocimiento de diversos casos que aporten la experiencia y que permitan por tanto generalizar de casos anteriores a nuevos casos, abstrayendo las principales características y desechando toda aquella información que pueda resultar de poca importancia.
- Asocian y generalizan sin reglas: Tal como lo hace el cerebro humano
- Requieren de algún tipo de patrón: Las RNA, no son capaces de reconocer nada que no tenga adjuntamente algún tipo de patrón. Es por esto, que no pueden predecir la lotería ni las carreras de caballos ya que por definición son procesos al azar.
- La solución dependerá de la forma de hacer las conexiones: Así como existen varias formas de conectar neuronas biológicas en nuestro cerebro; la solución a un problema variará de acuerdo a la topología de una RNA.
- Tienen capacidad de predecir los valores de salida con base en valores de entrada recibidos
- Tienen alta plasticidad y adaptabilidad que se debe a su capacidad de aprendizaje y por lo tanto son capaces de cambiar dinámicamente junto con el medio gracias a que las sinápsis (pesos) se adaptan para que la red responda de un modo distinto a los estímulos del medio.
- Funcionan "en paralelo" y pueden procesar la información procedente de fuentes no-lineales

Existe un gran número de modelos de redes y cada uno de ellos es disponible en diferentes formas. Debajo de muestra una clasificación de las redes más comúnmente empleadas:



El presente trabajo trata de redes tipo perceptrón multicapa (multi-layer perceptrón) con la regla de aprendizaje de retropropagación (backpropagation) y el entrenamiento supervisado (Rumelhart, McClelland 1986).

Las RNA tienen sus cimientos en 3 características básicas del cerebro humano:

- distribución del conocimiento en muchas neuronas dentro del cerebro
- posibilidad de comunicación (local) entre las neuronas
- adaptabilidad del cerebro

El objetivo de la invención de la neurona artificial no es el de trabajo solitario, sino de interconexión entre varias neuronas.

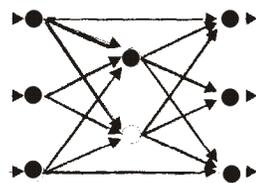
La unidad de proceso tiene sentido solo como parte de una red compuesta de elementos homogéneos. En las RNA, las neuronas son por lo regular interconectadas formando una estructura rígida de red. A diferencia del sistema biológico, el algoritmo de aprendizaje no contempla la formación de las nuevas conexiones y la eliminación de las viejas, éstas permanecen fijas desde inicio del diseño de la arquitectura de la red.

Hay tres tipos de redes neuronales: de perceptrón, de funciones de base radial y maquinas de soporte vectorial. El presente trabajo solo trata de redes tipo perceptrón.

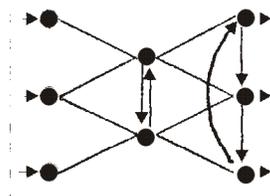
En RNA se emplea la estructura de conexión formada por capas, donde la capa de entrada recibe las señales de entrada, mientras que la capa de salida contiene los resultados. Las capas que se encuentran entre la capa de entrada y la capa de salida se llaman capas ocultas.

Hay diferentes formas de vinculación o conexión entre las capas de una red: hacia adelante, lateral y hacia atrás.

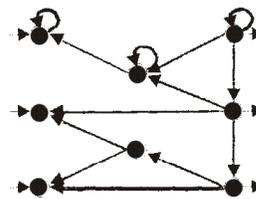
### TIPOS DE CONEXIONES



HACIA  
ADELANTE

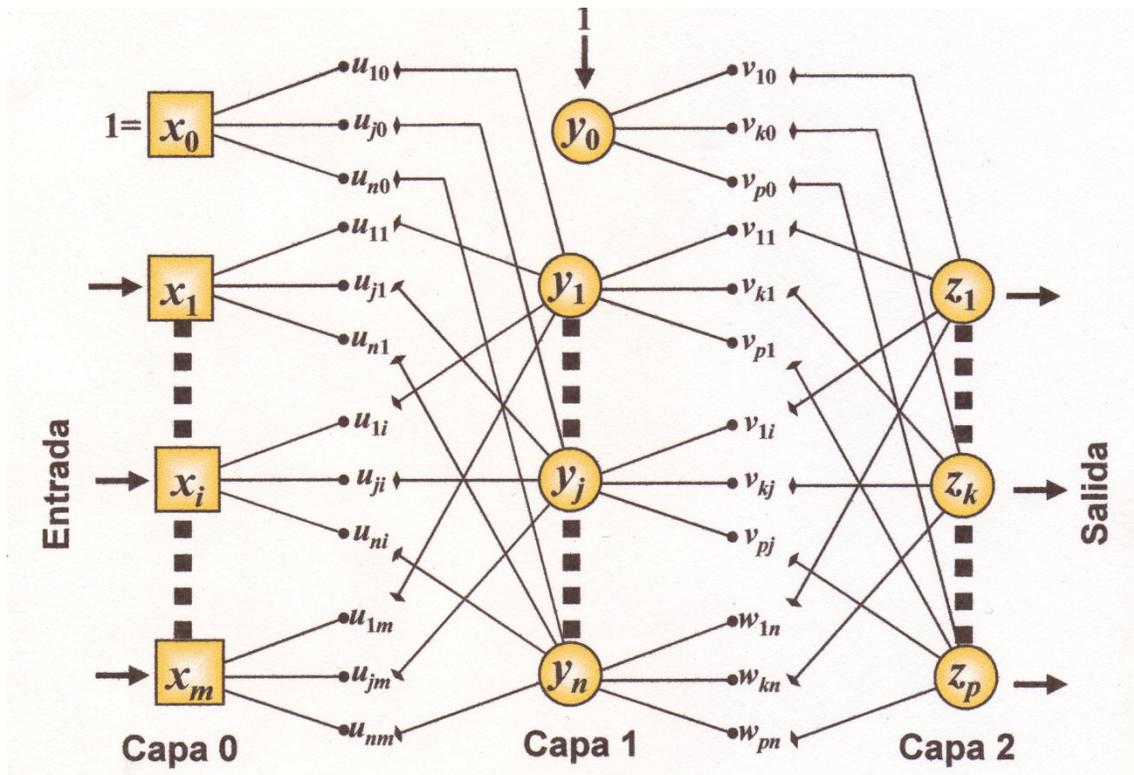


LATERAL



HACIA  
ATRÁS

Ahora bien, la pregunta es: ¿cuántas capas ocultas se necesita en una RNA? El teorema matemático, que por razones obvias no se expondrá en el presente trabajo, dice que se necesita dos capas ocultas si la función que representa a los datos de entrada es discontinua, mientras que si la función es continua se necesita de una capa oculta. En realidad, si el procesamiento de datos previo al entrenamiento fue correcto, toda red necesita solo de una capa oculta. Esto se explicará más a fondo a continuación.



### ESQUEMA DE UNA RED NEURONAL:

#### CAPA 0 O DE ENTRADA - CAPA 1 U OCULTA - CAPA 2 O DE SALIDA

Cabe señalar que la red no debe recibir los datos “crudos”, o sea tal cual se presentan en la muestra. Éstos, deben pasar necesariamente por tres etapas antes de alimentar con ellos la red, esto con la finalidad de que ésta pueda procesarlos exitosamente y aprender de ellos de manera correcta. Estas etapas son las siguientes:

- análisis de correlaciones (lineales) - si la muestra presenta variables altamente correlacionadas se debe escoger solo una de ellas y las de más deben ser eliminadas
- escalamiento (normalización) – por medio de la fórmula:  

$$x_n^* = (x_n - x_{\min}) / (x_{\max} - x_{\min})$$
 su aplicación mapea los valores al intervalo (0,1)
- análisis de la densidad de los datos – si la representación gráfica de los datos no es homogénea, hay “huecos” en la información, es decir la función

que representa los datos no es continua se debe realizar la interpolación<sup>3</sup> por medio de splines naturales<sup>4</sup> y de este modo obtener una función continua que representa a los datos a tratar;

Se puede concluir por lo tanto, respondiendo al mismo tiempo a la pregunta del número de capas ocultas, que sometiendo los datos a los tres procedimientos arriba mencionados, el número de capas ocultas de una RNA siempre será una.

Por lo tanto la arquitectura de cualquier RNA consiste en una capa de entrada, una capa oculta y una capa de salida.

La siguiente pregunta es: ¿cuántas neuronas necesita cada una de las capas?

La capa de entrada (input) necesita tantas neuronas cuantas variables contiene la muestra, mientras que el número de neuronas de salida corresponde al número de variables dependientes (1). El número de neuronas de la capa oculta se determina mediante la siguiente ecuación<sup>5</sup>:

---

<sup>3</sup> En el subcampo matemático del análisis numérico, se denomina **interpolación** a la construcción de nuevos puntos partiendo del conocimiento de un conjunto discreto de puntos. Un problema estrechamente ligado con el de la interpolación es la aproximación de una función complicada por una más simple. Si tenemos una función cuyo cálculo resulta costoso, podemos partir de un cierto número de sus valores e interpolar dichos datos construyendo una función más simple. En general, por supuesto, no obtendremos los mismos valores evaluando la función obtenida que si evaluásemos la función original, si bien dependiendo de las características del problema y del método de interpolación usado la ganancia en eficiencia puede compensar el error cometido.

En todo caso, se trata de, a partir de  $n$  parejas de puntos  $(x_k, y_k)$ , obtener una función  $f$  que verifique

$$f(x_k) = y_k, k = 1, \dots, n$$

a la que se denomina **función interpolante** de dichos puntos. A los puntos  $x_k$  se les llama **nodos**. Algunas formas de interpolación que se utilizan con frecuencia son la interpolación lineal, la interpolación polinómica (de la cual la anterior es un caso particular), la interpolación por medio de spline o la interpolación polinómica de Hermite.

<sup>4</sup> Un *spline* es una curva definida a trozos mediante polinomios. En los problemas de interpolación, se utiliza a menudo la interpolación mediante splines porque da lugar a resultados similares requiriendo solamente el uso de polinomios de bajo grado. El conjunto de splines constituye curvas más suaves que un polinomio de grado  $n-1$  y por eso reciben la denominación de naturales.

<sup>5</sup> Dr. Angel Fernando Kuri Morales; profesor de tiempo completo del departamento Académico de Computación, ITAM. El número pequeño de conexiones puede provocar que la red no aprenda lo suficiente para poder dar buenos resultados, mientras que el número elevado de ellas puede contribuir a la pérdida de la capacidad de generalización de la red, que va a poder reproducir el modelo aprendido con exactitud, mientras que la solución del nuevo problema tendrá un error elevado.

$$(I+1)H + (H+1)O = C$$

Donde:

I – nº de neuronas de entrada (input)

O – nº de neuronas de salida (output)

C – número de conexiones entre neuronas que debe equivaler a la tercera parte de la muestra; si su número es mayor se corre el riesgo de que la red aprenda de memoria. ( $C \approx S/3$ , S – nº de elementos de la muestra training)

H – el nº de neuronas de la capa oculta

Por lo tanto:

$$H = [(S/3)-O] / (I+1+O)$$

De lo anterior se concluye que para cada problema hay una arquitectura de la red distinta, que depende del tamaño de la muestra y del número de variables dependientes.

## EL ENTRENAMIENTO O EL PROCESO DE APRENDIZAJE DE LA RED

Después de haber realizado el análisis de correlaciones, el escalamiento y el análisis de la densidad de datos, así como una vez diseñada la arquitectura de la red (nº de neuronas de cada capa y nº de conexiones) se puede proceder con la fase de entrenamiento o proceso de aprendizaje.

Para llevar a cabo la clasificación, la red debe aprender alimentándose de ejemplos de datos conocidos. El conocimiento adquirido es distribuido a lo largo de la red en los pesos de conexión. Estos pesos, en la fase de entrenamiento, se ajustan para resolver el problema. Esto es posible gracias a las reglas de aprendizaje o algoritmos<sup>6</sup>. En el sistema biológico, el proceso de aprendizaje se da también por medio de adaptación estructural, lo que quiere decir que algunas conexiones entre neuronas pueden desaparecer y pueden establecerse otras, totalmente nuevas conexiones. En el caso de RNA esto no pasa.

Hay tres procesos o formas de aprendizaje:

- Supervisado
- No supervisado
- Estocástico<sup>7</sup>

En el caso de aprendizaje supervisado para el proceso de entrenamiento se debe tener una muestra con todos los datos conocidos (variables independientes y variable(s) dependiente(s)). Esta muestra se debe dividir en dos partes: 80% servirá como datos de entrenamiento, mientras que el 20% restante servirá como datos para realizar la prueba, que debe comprobar la efectividad de aprendizaje.

El proceso de entrenamiento es el siguiente: a la red se alimenta con la muestra conocida de datos de aprendizaje o de entrenamiento (80%). Inicialmente se asignan valores aleatorios a los pesos de las neuronas, cuyas magnitudes deben encontrarse entre 0.1 y 0.9, para permanecer dentro del rango de la función

---

<sup>6</sup> **algoritmo** (del latín, *dixit algorithmus*) es una lista bien definida, ordenada y finita de operaciones que permite hallar la solución a un problema.

<sup>7</sup> Se denomina **estocástico** a aquel sistema que funciona, sobre todo, por el azar. La palabra proveniente del griego: *στοχαστικός*, hábil en conjeturar. Significa "perteneciente o relativo al azar" según el DRAE.

sigmoidea. La red calcula los datos de salida con base en datos de entrada y los compara con los datos de salida conocidos. Se obtiene una señal de error que deriva de la diferencia entre los datos de salida generados y los datos de salida conocidos. Esta señal es empleada para modificar los pesos de acuerdo con las reglas de aprendizaje (algoritmo de retropropagación o backpropagation<sup>8</sup>) y como resultado se obtiene la reducción del error. Los pesos entre la capa de entrada y la capa oculta siempre se modifican con cambios más bruscos que los pesos entre la capa de salida y la capa oculta, donde se da la “sintonía fina” de la red.

$$I \quad \eta_1 \quad H \quad \eta_2 \quad O$$

$$\eta_1 > \eta_2$$

$\eta_1$  – ETA 1, learning factor o tasa de aprendizaje entre la capa de entrada y La capa oculta

$\eta_2$  - ETA 2, learning factor o tasa de aprendizaje entre la capa oculta y la capa de salida

La secuencia completa de entrenamiento es conocida como una Época. Puede haber muchas épocas y el entrenamiento se detiene cuando la red responda correctamente al entrenamiento, o sea hasta que la red alcanza el umbral de error mínimo definido. Posteriormente se alimenta a la red con una muestra de datos sin la variable dependiente y se realiza el cálculo de ésta última para comprobar la capacidad de aprendizaje de la red.

La selección de la muestra para el aprendizaje constituye un aspecto de suma importancia. Ésta debe ser un reflejo de los datos que se aportarán a la red en la

---

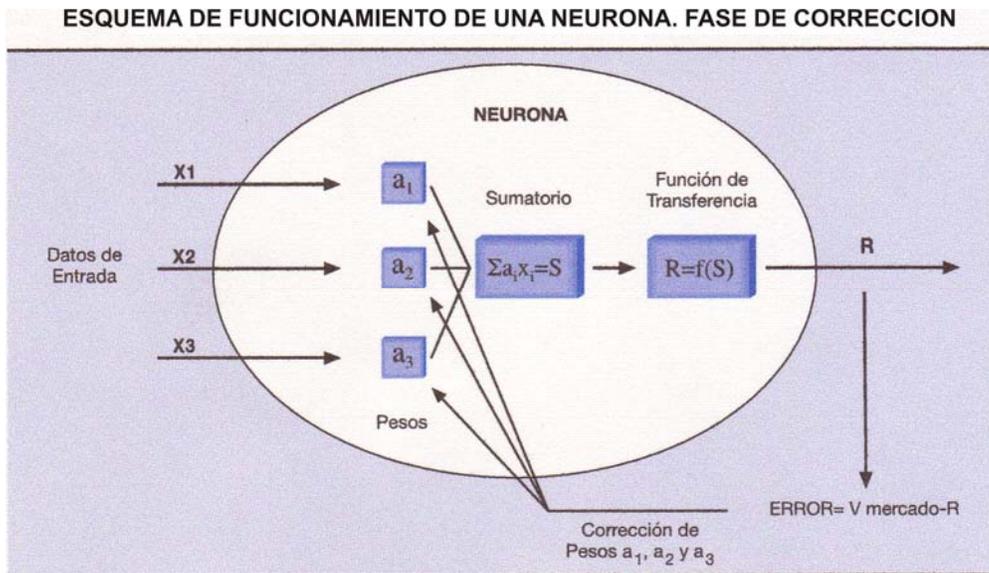
<sup>8</sup> algoritmo de retropropagación o backpropagation no es otra cosa que una generalización de la regla Delta. Regla Delta o método del gradiente descendente es el método para obtener los pesos óptimos que consiste en el siguiente proceso:

1. Se inicializan los pesos aleatoriamente
2. Se determina la dirección de la pendiente más pronunciada en dirección hacia abajo
3. Se modifican los pesos para descender un poco más abajo en la superficie.
4. Siendo  $W(t)$  el vector de peso en el instante  $t$ , en  $t+1$ :  $W(t+1)=W(t)+\Delta W(t)$

fase de predicción; es obvio que la red puede dar buenos resultados solamente con base en lo aprendido anteriormente.

En resumen, para cada época la RNA calcula el error en la capa de salida; entonces lo propaga a la capa oculta; inmediatamente el algoritmo ajusta los pesos de cada neurona y vuelve a calcular el error; repitiendo el procedimiento hasta que la Suma del Cuadrado del Error, sea muy próximo a cero.

$$\sum (salida_{RNA} - entrada_{Datos})^2 \cong 0$$



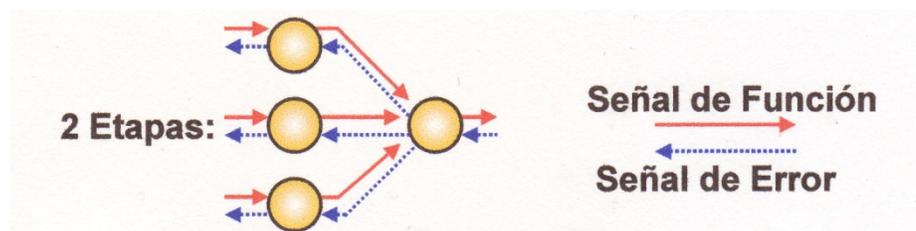
En el proceso de aprendizaje participa la neurona de umbral (bias neuron) cuyo input está fijado en 1. Esta neurona condiciona el disparo de la función de transferencia. La neurona de umbral se conecta a todas las neuronas de la red y actúa como un umbral ajustable para excitar a las neuronas. Los pesos de la neurona del umbral se ajustan junto con los pesos de las demás neuronas, haciendo evitar la configuración manual.

Este proceso de aprendizaje es análogo al aprendizaje del cerebro: el sistema se ajusta probando. Además del cálculo del error y su retropropagación existen

otros parámetros que se aplican a la RNA durante su aprendizaje para garantizar su correcto entrenamiento:

- a) Cálculo de ratio de aprendizaje - indica la parte del error que se corrige en cada época; un ratio de 0.1 significa que se corrigió 10% del error; el ratio es importante porque no se puede corregir el error bruscamente, porque esto afecta la estabilidad de RNA; por el contrario se debe corregirlo poco a poco; una red neuronal tipo perceptrón multicapa tiene la ventaja de poder tener diferentes ratios de aprendizaje en cada una de las capas, dónde el ratio debe cumplir la siguiente condición:  
 $0 < \text{ratio de aprendizaje} < (n^{\circ} \text{ de neuronas de la capa anterior})$
- b) momento - parámetro que suaviza el proceso de corrección; cuando se detecta el error, en lugar de corregirlo como lo indica el ratio de aprendizaje, se realiza una corrección intermedia entre el error actual e inmediatamente anterior, el momento permite que una muestra defectuosa no desvíe de forma sustancial la forma de aprendizaje;
- c) ruido de entrada – deforma de manera aleatoria las variables en un porcentaje, su función es la de evitar que un grupo de muestras demasiado perfectas impida que la RNA capte un modelo que sea generalizable;

Recapitulando, una RNA tiene entonces dos etapas de funcionamiento: la etapa hacia delante cuyo protagonista es la señal de función – es el estímulo que entra en la capa de entrada (capa 0) y pasa hacia delante por capa oculta hasta la capa de salida donde se genera la señal de salida. La segunda es la etapa hacia atrás es la retropropagación del error. Cuando se corrigen los pesos de las sinápsis, primero se corrigen las de la capa de salida, para posteriormente pasar por la capa oculta y llegar hasta la capa de entrada. El protagonista de esta etapa es la señal de error.



Es obvio que mientras más variables de entrada haya, se necesita más muestras de prueba y habrá más épocas o ciclos de entrenamiento.

Para no sobreentrenar la red es necesario disponer de un número de muestras de comprobación que sirven para verificar si faltan o sobran las épocas de entrenamiento y de las cuales, al igual que en el caso de las muestras de entrenamiento, se conoce la variable dependiente. El nivel de error admisible para la RNA es 5%. Cabe señalar que es necesario entrenar las RNA para la valuación inmobiliaria periódicamente dado el carácter cambiante del mercado inmobiliario.

A la fase de entrenamiento o aprendizaje sucede la de la producción, donde en el caso de la valuación inmobiliaria se cargará variables para obtener el valor de mercado.

En el caso de aprendizaje no supervisado, la red debe encontrar un criterio de clasificación solamente con base en los datos de entrada. La red intenta de encontrar características comunes entre los datos de entrada que tiene a disposición utilizando la “comparación por similitud” y adaptando de acuerdo a esto los pesos dentro de la estructura. Un ejemplo de este proceso fue desarrollado por Kohonen (Self – Organizing Feature Maps - 1989).

Aprendizaje estocástico emplea el proceso aleatorio y distribuciones de probabilidad para minimizar la función de energía de la red adecuadamente definida. Este proceso es análogo al del desarrollo o crecimiento de cristales: para obtener un cristal con el mínimo número de errores en su estructura reticular, éste debe ser enfriado muy lentamente, para asegurarse que las moléculas tengan suficiente tiempo para encontrar la posición, en la cual el total de la energía de la estructura llegue al mínimo. Mientras que la temperatura permanece suficientemente alta, las moléculas individuales pueden cambiar de posición, lo que se traduce en el incremento de la energía total. En la medida que la temperatura baja, la probabilidad que esto ocurra disminuye.

## **CAPÍTULO III**

### **APLICACIÓN DE LAS RNA**

Como ya se ha mencionado las primeras RNA fueran diseñadas para el reconocimiento de patrones como reconocimiento de texto o formas. Después de los años 80 la inteligencia artificial se hizo más popular, aumentando considerablemente su campo de aplicación. Se ha diseñado RNA multicapa para modelar procesos mentales mucho más complejos, que el perceptrón no era capaz de resolver tales como la asociación de conceptos, deducción, inducción y razonamiento.

Los diferentes modelos de aprendizaje así como de tipologías de las RNA desarrollados en los últimos años han permitido su aplicación en diferentes campos cuales: economía (análisis de inversiones, análisis de riesgos en la concesión de créditos, detección del fraude en el I.V.A., mercadotecnia, planeación estratégica, predicción de valores en mercados accionarios), industria (eficiencia de máquinas), medicina (diagnóstico de enfermedades), periciales (reconocimiento de firmas), ingeniería civil (la valoración de efectos sísmicos, solución de problemas de gerencia de construcción, control activo estructural, diagnóstico de daño, valoración de daño, cálculo de niveles de agua en los ríos), etc.

### **APLICACIÓN DE LAS RNA EN LA VALUACIÓN INMOBILIARIA**

La aplicación de la informática en el campo de la valuación inmobiliaria empezó al principio de los años 80, mientras que la inteligencia artificial encontró su lugar en esta rama del conocimiento humano apenas hace 17 años.

Entre los pioneros en este campo, que realizaron una importante labor experimental se puede mencionar a Borst (1991 y 1995 – Nueva Inglaterra), Tay y Ho (1992 - Singapur), Do y Grudnitski (1992 – California), Evans (1993 – Reyno Unido), Worzala (1993 – Colorado), Cechin (2000 – Brasil).

La mayoría de los trabajos hasta ahora realizados en el campo de la valuación inmobiliaria tienen un enfoque comparativo entre las RNA y la regresión múltiple, enfocándose en la comparación de los valores de error calculados por ambos sistemas. En todos los casos los resultados son claros posicionando a las RNA en primer lugar con un porcentaje de error entre 5% y 10%, mientras que el de la regresión múltiple oscila entre 10% y 15%. Si bien en algunos casos los

resultados del cálculo de error son muy similares, los investigadores concuerdan en que las RNA son un sistema que se caracteriza por una mayor precisión con respecto a la regresión múltiple.

Sin embargo considero que no tiene ningún sentido comparar los resultados obtenidos por RNA con los de la regresión múltiple dado que se trata de dos procedimientos completamente distintos: la regresión múltiple no hace otra cosa que establece la relación lineal entre variables y si la relación no es lineal “la vuelve” lineal, mientras que las RNA son capaces de detectar las relaciones no lineales entre las variables, aprender de ellas y poder predecir el valor de la variable dependiente con un error mínimo.

Se considera importante para los fines de este documento, mencionar algunos de los trabajos más relevantes hasta ahora realizados aplicando las RNA en el campo de la valuación inmobiliaria, esto con la finalidad de presentar esta novedosa herramienta que es capaz de superar los inconvenientes que presentan los otros métodos como la regresión múltiple o la AHP.

Un trabajo interesante de aplicación de las RNA es el del análisis del efecto de la edad en el valor de las viviendas. Fue realizado por los profesores A. Quang Do, del Departamento de Finanzas de la Escuela de Administración de Negocios de la Universidad Estatal de San Diego y G. Grudnitski del Departamento de Contaduría de la Escuela de Administración de Negocios de la Universidad Estatal de San Diego en Diciembre de año 1992. El objetivo del trabajo fue examinar la relación que existe entre la edad de un inmueble de uso habitacional y su valor de mercado.

Aplicando técnicas estadísticas de regresión múltiple, se determinó que la edad de un inmueble es inversamente proporcional a su valor durante toda la vida útil del mismo, señalando sin embargo la presencia de errores significativos relacionados con la interacción entre las variables de comportamiento no-lineal, problemas de multicolinealidad entre las variables independientes y problemas de heterosedasticidad entre otros.

Como ya se ha mencionado las RNA son capaces de resolver con gran exactitud los problemas relativos a funciones no-lineales. Esto se debe a que mientras en las técnicas de regresión múltiple la función de activación es predeterminada, las RNA la autodeterminan “afinando” los parámetros que permiten el mejor ajuste a los datos recibidos. En otras palabras la función de activación tiene la particularidad de adaptarse muy bien a la solución de problemas.

Para realizar el experimento se selección de una muestra de 242 casas solas pertenecientes a vecindarios similares, durante el período Enero – Septiembre de 1991, en el suroeste de la ciudad de San Diego (California, EE.UU.). Las variables independientes seleccionadas fueron:

- a) Edad del inmueble
- b) N° de habitaciones
- c) N° de baños
- d) Superficie de construcción
- e) Superficie del predio
- f) N° de cajones de estacionamiento
- g) N° de estaciones de bomberos en el vecindario
- h) N° de niveles

La conclusión del experimento fue que la edad de un inmueble es inversamente proporcional a su valor, solamente durante los primeros 16 a 20 años de su vida útil. Después de este periodo la relación entre la variable edad y la variable valor es directamente proporcional. Este experimento demostró la superioridad de las RNA respecto a regresión múltiple que erróneamente determinaba que la variable edad y la variable valor eran inversamente proporcionales durante toda la vida útil de una vivienda.

En el año 2000 Olga Karakozova, realizó su tesis de maestría en la Academia Sueca de Economía y Administración de Negocios consistente en una investigación para determinar las ventajas de RNA respecto a la regresión múltiple, para la solución de problemas relacionados con la valuación inmobiliaria residencial en el área metropolitana de Helsinki, Finlandia.

Aplicando 6 modelos de RNA y 4 de regresión múltiple en tres series de datos (toda área metropolitana de Helsinki, solo ciudad de Helsinki y únicamente viviendas homogéneas en Helsinki) la autora llegó a la conclusión que en las 3 series de datos las RNA superaron a los modelos de regresión múltiple en trabajo de predicción con recomendación de aplicación de las RNA para las técnicas de valuación masiva de vivienda, no como sustituto de análisis econométricos sino como su complemento.

Otro ejemplo comparativo entre técnicas de regresión múltiple y RNA es el la determinación del precio unitario de los departamentos en la ciudad de Pampatar, Venezuela, ubicada en una isla caribeña de Margarita.

Como muestra se tomó 91 departamentos cuya compra-venta fue protocolizada en el cuarto trimestre del año 2001.

Se ha seleccionado las siguientes variables dependientes:

- a) Fecha
- b) Superficie de construcción
- c) N° de habitaciones
- d) N° de baños
- e) Edad
- f) Venta (variable cualitativa: departamento nuevo=1, departamento usado=0)
- g) Vista (variable cualitativa: departamento con vista al mar=1, departamento sin vista al mar=0)

La conclusión del estudio fue que las RNA explican con mayor precisión el valor unitario del departamento en la ciudad de Pampatar, Venezuela, siendo el coeficiente de determinación de la regresión múltiple 0.75, mientras el de las RNA 0.94.

Otro estudio comparativo entre las RNA y modelo hedónico fue realizado por Caridad y Ocerín J.M. y Cuellar Villamandos N. del Departamento de Estadística de la Universidad de Córdoba (2001). El estudio consiste en la valuación de los departamentos. Para analizar el precio de un bien en función de sus características, los estadistas utilizaron por un lado métodos hedónicos y por el otro la metodología de RNA. La conclusión fue que mientras el coeficiente de determinación ( $R^2$ ) del modelo hedónico era de 0.613, el de las RNA equivalía a 0.822, confiriendo a las RNA mayor poder de predicción que al modelo hedónico.

En abril 2004, Julio Gallego Mora Esparza realizó el trabajo *La inteligencia artificial aplicada a la valoración de inmuebles. Un ejemplo para valorar Madrid*, dónde al igual que los autores arriba mencionados realiza una experimento comparativo de valuación de inmuebles aplicando regresión múltiple y RNA y llega a la conclusión de que las RNA son más precisas que la regresión múltiple y se comportan mejor a la hora de tratar inmuebles atípicos.

En septiembre 2005 se publicó un artículo *APLICACIÓN DE LAS REDES NEURONALES ARTIFICIALES AL CAMPO DE LA VALORACIÓN INMOBILIARIA* donde el auto - Lara Cabeza - hace el análisis de la influencia de la variable zona (ubicación espacial del inmueble dentro de la ciudad) en el valor del inmueble por medio de RNA. Este estudio le permitió determinar el coeficiente de apreciación o depreciación económica de los bienes inmuebles estudiados. Como bien se sabe en la estimación de este coeficiente intervienen numerosos factores cuya ponderación y cuantificación es complicada debido a que en la mayoría de los

casos se trata de factores cualitativos relacionados de distintas maneras unos con otros (características sociales, culturales, económicas, historia de la zona, impactos y decisiones de índole política, etc). Dada la capacidad de las RNA de analizar simultáneamente las variables cualitativas y cuantitativas el autor realizó un experimento para estimar de manera implícita el coeficiente de depreciación – apreciación teniendo como hipótesis a contrastar: la RNA debe ser capaz de asignar a un inmueble un precio ponderado en función de su ubicación según las zonas preestablecidas y según el valor del suelo en estas. Como variables de entrada el autor seleccionó:

- Superficie de construcción
- Nº de habitaciones
- Nº de baños
- Nº de cajones de estacionamiento
- Estado de conservación
- Zona 1 (universitaria; uso principal: residencial y servicios)
- Zona 2 (periférica; uso principal: residencial)
- Zona 3 (monumental; uso principal: residencial y servicios)
- Zona 4 (de nueva expansión; uso principal: residencial)
- Zona 5 (marginal o deprimida; uso principal: residencial)
- Zona 6 (barrio tradicional; uso principal: residencial)
- Zona 7 (residencial; uso principal: residencial)
- Zona 8 (comercio; uso principal: servicios)
- Zona 9 (centro; uso principal: residencial y servicios)

La elección de delimitación de las zonas se hizo tomando en cuenta.

1. Características sociales, culturales y económicas de la población
2. Usos
3. Tipología de las construcciones

No se seleccionó como variable la edad de la construcción tomando en cuenta dos factores:

- a) las fuentes de la edad de los inmuebles son dudosas;
- b) las conclusiones del estudio arriba mencionado de Quang y Grudnitski ponen de manifiesto que la edad de un inmueble es inversamente proporcional a su valor sólo durante los dos primeros decenios de su

vida útil, y una vez transcurrido este periodo las dos variables pasan a relacionarse de manera proporcional;

Las variables: superficie de construcción, nº de habitaciones, nº de baños, nº de cajones de estacionamiento y estado de conservación fueron consideradas como variables cuantitativas, mientras que las 9 variables correspondientes a las 9 zonas de la ciudad fueron consideradas como variables cualitativas.

El estudio, tuvo como objeto cuantificar la influencia que sobre el precio de un bien inmueble ejerce su ubicación dentro de un espacio determinado, y como consecuencia del mayor o menor valor del suelo sobre el que se sitúa.

Las conclusiones del estudio fueron:

- la RNA ha sido capaz de asignar a los inmuebles testigos un precio ponderado en función de su ubicación dentro de las zonas preestablecidas con una diferencia relativa media de un 4.07%.
- algunos valores de diferencia relativa porcentual son excesivos, según los cálculos estadísticos, y por tanto, merecen un análisis aparte. Para tratar de determinar los motivos por los que se producen estas pequeñas anomalías, se analizó con detenimiento las zonas en las que se presentaron.
- La principal aportación de RNA radica en el manejo de la variable cualitativa “zona” que muestra su ventaja sobre otras técnicas de valuación como la regresión, dado que el factor “zona” no necesita de ningún ponderador numérico asociado a sí mismo para estimar el valor final. La RNA es capaz de establecer un criterio propio, basado en el aprendizaje, a la hora de ponderar cada una de las zonas, asignándole un precio determinado en función de los valores de los inmuebles empleados en la muestra; es la propia RNA la que estima de manera cuantitativa la influencia o el peso que sobre el valor final de la vivienda tienen las variables cualitativas como es la de “zona”
- A la hora de correr la RNA sin las 9 variables “zona”, La RNA tiene problemas en establecer el patrón de aprendizaje fiable, porque recibe información de entrada contradictoria: a inmuebles de iguales características le corresponden salidas diferentes (distinto valor de mercado).

## **CAPÍTULO IV**

### **CASO PRÁCTICO DE ESTUDIO**

#### **DETERMINACIÓN DE LOS VALORES DE LOS DEPARTAMENTOS EN LA DELEGACIÓN BENITO JUAREZ, MÉXICO D.F.**

##### **PROBLEMA:**

Dado un conjunto de variables que caracterizan a los departamentos, entrenar a la red para que determine los valores de los departamentos.

##### **BASE DE DATOS:**

Se tiene a disposición una base de datos de 143 departamentos ubicados en 35 colonias pertenecientes a la Delegación Benito Juárez. Los avalúos de los inmuebles fueron realizados en la Corporación Mexicana de Valuación S.A. de C.V. entre 9 de febrero y 26 de diciembre de 2007.

CONSECUTIVO	Nº INT. CMV	DIRECCION	C.P.	C.P.= LOC. (V1)	REF. DE PROX. URBANA (V2)	Nº DE NIVELES (V3)	VIDA ÚTIL REM. EN MESES (V4)	AÑO DE TERM. O REMODEL. DE LA OBRA (V5)	UNIDADES RENTABLES GENERALES (V6)	SUP DE TERRENO (V7)	SUP VENDIBLE (V8)	Nº DE REC (V9)	Nº DE BANOS (V10)	Nº MEDIOS BANOS (V11)	Nº DE ESTAC (V12)	ELEVADOR (V13)	FECHA DEL AVALUO (V14)	CLASE (V15)	VALOR CONCLUIDO (F)
1	47562	LEONARDO DA VINCI No Ext: 93 No Int: 303	03910	34	3	5	840	2007	3	31.31	68.81	1	1	0	1	0	09-feb-07	3	\$937.200.00
2	47658	ASTURIAS No Ext: 240 No Int: DEPTO-202	03400	27	2	5	480	1977	14	30.53	103.34	2	1	0	1	0	15-feb-07	3	\$1.140.900.00
3	47869	ALABAMA No Ext: 54 No Int: 801	03810	20	3	15	960	2007	17	29.02	126.73	3	3	0	2	1	14-feb-07	4	\$2.591.600.00
4	47888	MONROVIA No Ext: 310 No Int: C-301	03300	8	2	5	816	2005	9	46.62	99.50	3	2	0	2	0	19-feb-07	3	\$1.416.900.00
5	47917	CLAUDIO ARCINIEGA No Ext: 28 B -6 No Int: .	03910	34	3	5	360	1967	6	36.29	83.80	2	1	0	0	0	30-mar-07	3	\$618.400.00
6	47993	GUIPUZCOA No Ext: 36 No Int: EDIF A DEPTO 603	03430	11	2	10	840	2007	24	14.20	54.29	2	1	0	0	1	19-feb-07	3	\$643.300.00
7	47996	HILARIO PEREZ DE LEON No Ext: 21 No Int: 2	03440	12	2	5	360	1977	2	47.54	58.01	2	1	0	0	0	01-mar-07	2	\$531.400.00
8	48049	LUZ SAVINON No Ext: 601 No Int: DEPTO 501	03100	4	2	10	840	2007	3	22.71	68.36	2	1	0	2	1	20-feb-07	3	\$1.228.400.00
9	48187	TIBURCIO SANCHEZ DE LA BARQUERA No Ext: 19	03930	22	3	10	780	2002	30	16.00	60.47	2	1	0	1	0	26-feb-07	3	\$840.000.00
10	48267	23 No Ext: 29 No Int: PH-4	03800	19	2	10	840	2007	4	19.83	60.51	2	2	0	1	1	26-feb-07	3	\$927.600.00
11	48271	AV. CUAUHTEMOC No Ext: 1378 No Int: 303	03310	9	1	10	840	2007	21	17.75	68.63	2	1	0	1	1	09-feb-07	3	\$925.800.00
12	48337	CALZ DE TLALPAN 572 CONJ CONDOMINAL HABT No Ext: TORRE C No Int: DEPTO 402	03510	13	2	10	840	2007	44	16.39	60.00	2	1	0	1	1	28-feb-07	3	\$808.800.00

13	48343	RAFAEL SOLANA No Ext: 34 No Int: DEPTO 204	03630	16	2	10	840	2007	28	16.61	56.06	2	1	0	1	1	20-mar-07	3	\$744.500.00
14	48434	MAYORAZGO DE ORDUÑA No Ext: 34 No Int: DEPTO A	03330	10	2	5	960	2007	12	75.57	120.29	3	3	0	2	0	14-mar-07	4	\$2.178.500.00
15	48435	MAYORAZGO DE ORDUÑA No Ext: 34 No Int: C-103	03330	10	2	5	960	2007	12	75.57	114.48	3	3	0	2	0	15-mar-07	4	\$2.166.000.00
16	48906	NINOS HEROES DE CHAPULTEPEC No Ext: 102 No Int: B-112	03440	12	2	10	840	2007	60	13.62	53.92	2	1	0	1	0	28-may-07	3	\$650.300.00
17	49014	MIRAMAR No Ext: 935 No Int: DEPTO 302	03580	14	2	10	840	2007	15	13.20	54.84	2	1	0	0	0	12-mar-07	3	\$731.600.00
18	49408	GABRIEL MANCERA No Ext: 1162 No Int: DEPTO-4	03100	4	2	5	420	1972	12	29.18	79.77	3	1	0	0	0	21-mar-07	3	\$855.900.00
19	49451	TLALPAN No Ext: 572 No Int: E-306	03510	13	2	10	840	2007	44	16.69	58.78	2	1	0	1	0	20-mar-07	3	\$794.100.00
20	49937	FERNANDO MONTES DE OCA No Ext: 114 No Int: DEPTO- 403	03610	15	2	10	840	2007	27	17.94	69.69	2	1	0	1	0	27-mar-07	3	\$887.200.00
21	49938	INDIANAPOLIS No Ext: 89 No Int: C-315	03810	20	3	10	840	2007	75	18.50	61.82	2	1	0	1	1	30-jul-07	3	\$1.114.600.00
22	50101	LAGO PONIENTE No Ext: 44 No Int: 1-B	03610	15	2	5	684	1994	10	34.85	68.53	2	1	0	2	0	11-abr-07	3	\$820.300.00
23	50320	LEONARDO DA VINCI No Ext: 166 No Int: DEPTO 101	03910	34	3	10	840	2007	18	16.02	64.20	2	1	0	1	0	11-abr-07	3	\$891.700.00
24	50469	KENTUCKY No Ext: 14 No Int: DEPTO 3	03810	20	3	5	828	2006	8	30.16	111.32	2	2	0	2	0	10-abr-07	3	\$1.882.400.00
25	50504	RODRIGUEZ SARO No Ext: 108 No Int: DEPTO 201	03230	6	3	5	948	2006	14	35.47	99.89	2	2	0	2	1	11-abr-07	4	\$1.913.900.00
26	50523	CONCEPCION BEISTEGUI No Ext: 2103 No Int: 203-G	03020	2	2	5	408	1971	140	53.03	114.00	2	3	0	1	0	12-abr-07	3	\$1.116.000.00

27	50558	AV. DEL PARQUE No Ext: 28 No Int: 201	03810	20	3	10	840	2007	10	19.71	87.00	2	2	0	2	1	03-abr-07	3	\$1.711.000.00
28	50571	DR. ANDRADE( HOY ATENOR SALAS) No Ext: 459 No Int: DEPTO 1 P. B.	03010	1	2	5	600	1987	10	28.87	69.92	3	1	0	1	0	16-abr-07	3	\$743.900.00
29	50574	CALZ. DE SANTA CRUZ No Ext: 73 No Int: EDIF. B 202	03660	17	2	5	828	2006	8	27.21	67.00	2	2	0	1	0	02-may-07	3	\$771.200.00
30	50675	INDIANA No Ext: 25 No Int: 404	03810	20	3	10	960	2007	35	28.14	109.43	3	2	0	2	1	13-abr-07	4	\$1.819.800.00
31	50677	NUEVA YORK No Ext: 58 No Int: 302	03810	20	3	5	804	2004	7	34.13	89.95	2	1	0	1	0	13-abr-07	3	\$1.391.500.00
32	50693	BOTICELLI No Ext: 53 No Int: DEPTO 203	03700	18	3	5	840	2007	15	33.12	94.00	3	2	0	2	1	17-abr-07	3	\$1.449.500.00
33	50902	TIGRE No Ext: 22 No Int: DEPTO 302	03104	5	2	10	504	1979	17	23.56	87.96	2	2	0	1	0	23-abr-07	3	\$1.067.800.00
34	50924	SATURNINO HERRAN No Ext: 60 No Int: 401	03900	21	3	10	708	1986	14	22.45	120.00	2	2	1	1	1	30-abr-07	4	\$1.747.200.00
35	50988	ASTURIAS No Ext: 157 No Int: DEPTO 102	03400	27	2	10	480	1977	12	22.12	82.67	2	1	0	1	0	23-abr-07	3	\$913.500.00
36	50989	SAN FRANCISCO No Ext: 1800 No Int: DEPTO 601	03240	7	1	10	384	1969	16	20.59	86.32	2	1	0	1	1	27-abr-07	3	\$984.900.00
37	51191	AV. CUMBRES DE MALTRATA No Ext: 359 No Int: DEPTO 303	03023	3	2	5	360	1967	16	13.50	66.58	2	1	0	0	0	24-abr-07	3	\$709.100.00
38	51492	TENNESSE No Ext: 30 No Int: DEPTO B-201	03810	20	3	10	960	2007	17	28.48	118.66	2	2	0	2	1	02-may-07	4	\$2.054.000.00
39	51499	TENNESSE No Ext: 30 No Int: 401	03840	33	3	10	960	2007	17	45.14	164.85	3	3	1	2	1	30-abr-07	4	\$2.756.300.00
40	51892	MIGUEL NORENA No Ext: 43 No Int: 5	03900	21	3	10	600	1987	10	24.52	74.13	3	1	0	1	0	11-may-07	3	\$1.188.300.00

41	51919	AV. REVOLUCION No Ext: 397 No Int: 203	03820	32	3	15	960	2007	23	20.29	101.24	3	2	0	1	1	21-may-07	4	\$1.405.200.00
42	52028	LOUISIANA No Ext: 200 No Int: 201	03810	20	3	5	840	2007	8	31.58	88.19	2	2	1	1	1	16-may-07	3	\$1.599.800.00
43	52094	GABRIEL RAMOS MILLAN No Ext: 117 No Int: E	03440	12	2	10	840	2007	20	29.10	88.45	3	2	0	2	1	27-ago-07	3	\$1.235.600.00
44	52152	ANGEL URRAZA No Ext: 905 No Int: 9	03100	4	2	5	240	1967	13	18.02	55.38	2	1	0	0	0	06-jun-07	2	\$472.900.00
45	52266	AV. POPOCATEPETL No Ext: 295 No Int: 17	03310	9	1	5	420	1972	25	14.60	44.82	2	1	0	0	0	10-may-07	3	\$500.000.00
46	52420	OBRERO MUNDIAL No Ext: 246 No Int: DEPTO 6	03103	23	3	5	396	1970	8	34.84	129.06	3	2	0	0	0	02-may-07	3	\$1.223.500.00
47	52617	FILIPINAS No Ext: 1225 No Int: DEPTO 103	03300	8	2	10	840	2007	15	20.79	73.50	2	2	0	1	1	26-jul-07	3	\$1.109.100.00
48	52619	GEORGIA No Ext: 13 No Int: DEPTO 203	03810	20	3	10	936	2005	23	22.18	85.44	2	2	0	1	1	03-may-07	4	\$1.342.300.00
49	52838	AV. GABRIEL RAMOS MILLAN No Ext: 117 No Int: DEPTO 103	03440	12	2	10	840	2007	20	29.10	93.51	3	2	0	2	1	03-may-07	3	\$1.281.100.00
50	53058	ALBERT No Ext: 46 No Int: B-101	03560	28	2	5	816	2005	3	47.30	90.00	2	2	0	1	0	29-jun-07	3	\$1.243.800.00
51	53059	SAN BORJA No Ext: 1758 No Int: DEPTO B-403	03630	16	2	10	840	2007	20	25.31	79.10	2	2	0	1	1	29-jun-07	3	\$1.138.200.00
52	53257	CASAS GRANDES No Ext: 19 No Int: DEPTO-302	03023	3	2	5	840	2007	7	65.13	118.52	3	2	0	1	0	11-jun-07	3	\$1.774.200.00
53	53368	ANDREA DEL CASTAGNO No Ext: 38 No Int: DEPTO 404	03700	18	3	10	840	2007	20	16.07	60.01	2	2	0	1	1	31-jul-07	3	\$886.300.00
54	53531	FELIPE CARRILLO PUERTO No Ext: 310 MOD. JACARANDAS No Int: PH-301	03340	26	1	5	912	2003	66	63.64	128.00	3	3	1	2	0	20-may-07	4	\$2.160.000.00

55	53533	PAZ MONTES DE OCA No Ext: 45 No Int: B-201	03340	26	1	5	840	2007	28	37.40	78.81	2	2	0	2	0	30-may-07	3	\$1.420.000.00
56	53607	CALZ. DE TLALPAN No Ext: 572 No Int: DEPTO E-702	03510	13	2	10	840	2007	44	16.57	58.20	2	1	0	1	1	11-jun-07	3	\$789.800.00
57	53625	PRIVADA LAGO No Ext: 31 No Int: 302	03610	15	2	10	840	2007	15	18.53	62.55	2	1	0	1	1	31-jul-07	3	\$809.400.00
58	53626	PRIVADA LAGO No Ext: 31 No Int: 109	03610	15	2	10	840	2007	15	17.42	58.82	2	1	0	1	1	05-jun-07	3	\$774.100.00
59	53627	RAFAEL SOLANA No Ext: 34 No Int: 502	03630	16	2	10	840	2007	28	16.61	61.40	2	1	0	1	1	29-jun-07	3	\$783.500.00
60	53629	PALENQUE No Ext: 17 No Int: 302	03010	1	2	10	840	2007	15	13.26	45.95	2	1	0	0	1	30-ago-07	3	\$636.400.00
61	53704	ALHAMBRA No Ext: 1206 No Int: 102-B	03300	8	2	5	840	2007	6	35.83	76.50	2	2	0	1	0	12-jun-07	3	\$994.500.00
62	53744	SAN FRANCISCO No Ext: 1656 No Int: DEPTO 303	03100	4	2	5	804	2004	3	58.39	137.75	3	2	0	2	1	21-jun-07	3	\$2.109.000.00
63	53790	PIRINEOS No Ext: 142 No Int: DEPTO 503	03300	8	2	10	0	1937	15	24.48	104.14	3	2	0	1	0	20-jun-07	3	\$1.327.700.00
64	53966	JORGE WASHINGTON No Ext: 64 No Int: DEPTO 302	03510	13	2	10	444	1974	9	18.89	60.74	2	1	0	0	0	20-jun-07	3	\$556.400.00
65	53969	MONTE ALBAN No Ext: 387 No Int: 5	03600	30	1	5	276	1970	6	26.67	53.35	2	1	0	1	0	25-jun-07	2	\$524.400.00
66	54373	ZARATOGA No Ext: 1117 No Int: 403	03300	8	2	5	540	1982	16	16.97	55.00	2	1	0	1	0	25-jun-07	3	\$585.800.00
67	54386	CASTILLA No Ext: 182 No Int: 204	03400	27	2	10	840	2007	22	19.88	70.38	3	2	0	1	1	20-jul-07	3	\$892.400.00
68	54502	PALENQUE No Ext: 90 No Int: DEPTO 2	03023	3	2	5	732	1998	4	40.31	74.88	2	2	0	1	0	28-jun-07	3	\$1.016.900.00
69	54553	INDIANA No Ext: 288 No Int: D 404	03710	31	2	10	840	2007	20	27.35	100.00	3	2	0	2	0	26-jun-07	3	\$1.725.000.00

70	54640	MARIPOSA No Ext: 1000 No Int: 102	03340	26	1	5	468	1976	13	23.49	69.57	2	1	0	1	0	04-jul-07	3	\$793.700.00
71	54747	ALBERT No Ext: EDIF. 25 No Int: DEPTO 001	03560	28	2	5	840	2007	28	16.77	55.26	2	2	0	1	1	05-jul-07	3	\$816.200.00
72	54809	EXTREMADURA No Ext: 158 No Int: DEPTO 1	03920	35	3	5	504	1979	10	30.23	91.84	2	1	1	1	0	05-jul-07	3	\$960.600.00
73	54810	AV. DOS No Ext: 84 No Int: 203	03800	19	2	5	840	2007	14	26.77	71.53	2	2	0	2	1	09-jul-07	3	\$1.182.300.00
74	54870	PATRICIO SAENZ No Ext: 616 No Int: DEPTO 302	03100	4	2	5	960	2007	5	49.63	130.00	3	2	0	2	1	09-jul-07	4	\$2.147.600.00
75	54873	CORUÑA No Ext: 168 No Int: 53	03400	27	2	10	840	2007	22	17.50	65.35	2	2	0	1	1	02-ago-07	3	\$955.400.00
76	54874	5 DE FEBRERO No Ext: 1172 No Int: DEPTO 12	03440	12	2	5	336	1965	14	13.97	42.70	1	1	0	0	0	05-jul-07	3	\$384.700.00
77	55061	AV. DOS No Ext: 84 No Int: 101	03800	19	2	5	840	2007	14	28.47	76.33	2	2	0	1	1	30-jul-07	3	\$1.183.800.00
78	55062	INDIANA No Ext: 86 No Int: 203	03810	20	3	5	600	1987	16	33.81	96.56	3	1	1	0	0	05-jul-07	3	\$1.076.600.00
79	55071	DR. JOSE MARIA VERTIZ No Ext: 907 No Int: 302	03023	3	2	10	840	2007	20	14.66	64.90	2	1	0	1	1	05-jul-07	3	\$887.800.00
80	55347	BERLIN No Ext: 40 No Int: DEPTO 203	03560	28	2	5	840	2007	3	42.50	87.80	3	2	0	1	0	02-ago-07	3	\$1.224.800.00
81	55348	DR. JOSE MARIA VERTIZ No Ext: 632 No Int: 201	03023	3	2	10	840	2007	15	15.13	54.00	2	1	0	1	0	25-jul-07	3	\$778.100.00
82	55349	ISABEL LA CATOLICA No Ext: 764 No Int: 201	03400	27	2	10	840	2007	32	13.50	53.10	2	1	0	0	1	13-ago-07	3	\$702.500.00
83	55412	10 DE MAYO No Ext: 100 No Int: DEPTO 410	03800	19	2	5	408	1971	10	30.70	71.30	2	1	0	1	0	16-jul-07	3	\$760.100.00
84	55414	LUZ SAVINON No Ext: 210 No Int: DEPTO 502	03100	4	2	10	600	1977	10	50.89	202.21	3	3	1	2	0	16-jul-07	4	\$2.523.600.00
85	55514	AV. CUAUHTEMOC No Ext: 977 No Int: DEPTO 403	03100	4	2	10	840	2007	21	22.58	95.89	2	2	0	2	1	16-jul-07	3	\$1.699.200.00

86	56036	ADOLFO PRIETO No Ext: 1374 No Int: DEPT. 401	03100	4	2	10	396	1970	14	64.27	184.86	3	2	0	2	1	13-ago-07	3	\$2.172.100.00
87	56219	ILLINOIS No Ext: 64 No Int: DEPTO 402	03810	20	3	10	960	2007	10	26.27	84.39	2	2	0	2	1	26-jul-07	4	\$1.589.100.00
88	56412	PATRICIO SANZ No Ext: 44 No Int: ? PENDIENTE	03100	4	2	5	600	1987	9	34.65	80.44	2	1	0	0	0	01-ago-07	3	\$991.800.00
89	56453	JUAN DE LA BARRERA No Ext: 28 No Int: DEPTO 503	03440	12	2	10	840	2007	15	16.67	51.81	2	1	0	1	1	26-sep-07	3	\$729.000.00
90	56776	CALLE DOS No Ext: 20 No Int: 201	03800	19	2	10	828	2006	14	20.47	74.15	3	1	0	1	0	09-ago-07	3	\$1.075.000.00
91	56923	PESTALOZZI No Ext: SN DEPTO 102 No Int: 105	03020	2	2	5	360	1967	3	44.90	93.20	2	1	1	2	0	13-ago-07	3	\$1.005.600.00
92	57019	ALHAMBRA No Ext: 203 No Int: DEPTO 202	03300	8	2	5	840	2007	3	31.56	62.84	2	1	0	1	0	13-ago-07	3	\$882.900.00
93	57269	ALHAMBRA No Ext: 1110 No Int: 102	03300	8	2	5	840	2007	3	44.77	86.40	2	2	0	1	0	15-ago-07	3	\$1.146.500.00
94	57284	CORUÑA No Ext: 168 No Int: 54	03400	27	2	10	840	2007	22	17.54	65.35	2	2	0	1	1	13-ago-07	3	\$955.400.00
95	57698	AMORES No Ext: 133 No Int: DEPTO 201	03100	4	2	10	384	1969	52	30.87	134.49	2	3	0	1	1	27-ago-07	3	\$1.392.000.00
96	57731	ANTILLAS No Ext: 1206 No Int: DEPTO 103	03300	8	2	5	840	2007	11	31.42	66.80	2	2	0	1	0	28-ago-07	3	\$1.059.400.00
97	57923	DIVISION DEL NORTE No Ext: 443	03100	4	2	10	960	2007	64	29.40	109.70	3	2	0	1	1	27-ago-07	4	\$1.965.800.00
98	57961	FILIPINAS No Ext: 913 No Int: DEPTO 204	03300	8	2	5	840	2007	16	34.39	70.48	3	2	0	2	0	10-sep-07	3	\$1.107.200.00
99	57965	MORAS No Ext: 430 No Int: DEPTO B-105	03200	24	1	10	840	2007	40	44.92	91.55	2	2	0	2	1	03-sep-07	3	\$1.647.000.00
100	58171	ANTILLAS No Ext: 1206 No Int: DEPTO-201	03300	8	2	5	840	2007	11	42.04	83.97	2	2	0	1	0	28-ago-07	3	\$1.242.800.00
101	58538	EUGENIA No Ext: 314 No Int: 301	03100	4	2	10	960	2007	5	40.55	148.27	3	3	0	2	1	15-sep-07	4	\$2.482.000.00

102	58700	SAN FELIPE No Ext: 85 DEPTO 101 No Int: EDIFIC. K	03330	10	2	5	960	2007	12	84.31	122.52	3	2	1	2	0	27-sep-07	4	\$3.070.400.00
103	59017	AV REVOLUCION No Ext: 424 No Int: 22	03800	19	2	5	480	1977	25	32.18	73.20	2	1	0	0	0	29-oct-07	3	\$762.700.00
104	59021	PIRINEOS No Ext: 142 No Int: 101	03300	8	2	10	840	2007	15	22.98	97.71	3	2	0	0	1	26-sep-07	3	\$1.303.400.00
105	59024	MONROVIA No Ext: 403 No Int: 3	03303	25	2	10	840	2007	10	23.52	94.55	2	2	0	1	1	26-sep-07	3	\$1.338.800.00
106	59049	SAGREDO No Ext: 155 No Int: TORRE-2 depto 2042	03900	21	3	15	960	2007	147	19.28	93.00	2	2	0	1	1	21-sep-07	4	\$1.698.000.00
107	59053	TORRES ADALID No Ext: 1011 No Int: 202	03100	4	2	10	456	1975	16	23.98	67.44	2	1	0	0	0	27-sep-07	3	\$750.600.00
108	59537	BALBOA 702 INT 204	03300	8	2	10	396	1970	16	19.94	74.42	2	2	0	1	0	28-sep-07	3	\$771.000.00
109	59709	CALLE 2 No Ext: 40 No Int: 201	03800	19	2	10	840	2007	20	20.01	59.97	2	2	0	1	1	29-oct-07	3	\$842.600.00
110	59937	ADOLFO PRIETO No Ext: 1028 No Int: DEPTO 301	03100	4	2	10	504	1979	14	20.52	128.53	2	2	0	0	0	16-oct-07	3	\$1.312.300.00
111	59950	EJE 5 SUR EUGENIA No Ext: 1012 No Int: DEPTO 206	03100	4	2	10	840	2007	10	17.66	63.75	2	2	0	1	1	22-oct-07	3	\$1.184.500.00
112	60309	ADOLFO PRIETO No Ext: 19 No Int: 503	03100	4	2	10	528	1981	20	22.76	104.37	3	2	0	2	1	28-nov-07	3	\$1.274.400.00
113	60310	JUAN SANCHEZ AZCONA No Ext: 1613 No Int: 304	03104	5	2	10	504	1979	10	15.12	48.00	1	1	0	1	0	29-oct-07	3	\$602.900.00
114	60915	NIÑOS HEROES DE CHAPULTEPEC No Ext: 151 No Int: DEP 501-C	03440	12	2	10	828	2006	20	14.70	42.74	2	1	0	0	0	05-dic-07	3	\$570.200.00
115	61157	CONCEPCION BEISTEGUI # 2103 ENTRADA "A" DEPTO. 403	03600	30	1	5	408	1971	20	51.68	107.00	3	3	0	0	0	29-oct-07	3	\$1.093.500.00
116	61268	BENITO JUAREZ EDIF E No Ext: 89 No Int: 402	03570	29	2	5	372	1978	10	24.72	39.70	2	1	0	0	0	24-oct-07	2	\$326.700.00

117	61338	EJE CENTRAL LAZARO CARDENAS No Ext: 541 No Int: DEP 302	03023	3	2	10	840	2007	28	20.91	83.19	2	2	0	1	1	01-nov-07	3	\$1.207.900.00
118	61493	AV REVOLUCION No Ext: 425 No Int: 502	03820	32	3	10	840	2007	30	16.57	49.19	2	1	0	1	0	07-nov-07	3	\$616.400.00
119	62229	AV REVOLUCION No Ext: 424 No Int: 24	03800	19	2	5	480	1977	25	44.58	112.36	3	1	0	0	0	15-nov-07	3	\$1.125.800.00
120	62232	AV. COYOACAN No Ext: 1058 No Int: A-701	03100	4	2	15	504	1979	40	11.82	86.94	2	1	0	0	1	14-nov-07	3	\$883.300.00
121	62244	MONROVIA No Ext: 907 No Int: 002	03300	8	2	5	840	2007	8	29.52	59.02	2	1	0	2	0	13-nov-07	3	\$950.200.00
122	62510	AV. INDEPENDENCIA No Ext: 39 No Int: B.402	03630	16	2	10	768	2001	24	11.08	43.12	2	1	0	0	0	23-nov-07	3	\$574.800.00
123	62511	FELIX PARRA No Ext: 36 No Int: DEPTO 106	03900	21	3	10	840	2007	36	13.00	62.00	1	1	0	1	1	20-dic-07	3	\$1.146.400.00
124	62780	AV. COYOACAN No Ext: 1617 COND D No Int: DEPTO 403	03100	4	2	10	960	2007	23	33.59	105.41	3	2	0	2	1	04-dic-07	4	\$1.837.300.00
125	62881	DIAGONAL SAN ANTONIO No Ext: 1809 No Int: 404	03023	3	2	10	840	2007	29	22.96	106.13	3	2	0	2	1	06-dic-07	3	\$1.559.000.00
126	62886	SORIA No Ext: 160 No Int: 403	03400	27	2	5	840	2007	8	26.22	68.82	2	2	0	1	0	29-nov-07	3	\$970.400.00
127	63299	CEREZAS Lte: EDIF- A No Ext: 9 No Int: DEPTO 3	03100	4	2	10	480	1977	13	18.59	85.77	2	1	0	0	0	04-dic-07	3	\$1.083.300.00
128	63772	BELGICA No Ext: 914 No Int: B-44	03300	8	2	10	768	2001	20	13.13	47.60	2	1	0	1	0	05-dic-07	3	\$610.700.00
129	63780	ROCHESTER No Ext: 43 No Int: 302	03810	20	3	10	960	2007	10	30.78	96.35	3	2	0	1	0	06-dic-07	4	\$1.585.900.00
130	63781	FILIPINAS No Ext: 913 No Int: 206	03300	8	2	5	840	2007	8	32.75	66.11	3	2	0	2	0	04-dic-07	3	\$1.043.900.00
131	63782	MONROVIA No Ext: 907 No Int: 201	03300	8	2	5	840	2007	8	32.27	66.11	2	2	0	2	0	04-dic-07	3	\$1.043.900.00

132	63802	AV. 3 No Ext: 79 No Int: DEPTO 105	03800	19	2	5	816	2005	8	32.61	83.18	3	2	0	2	1	17-dic-07	3	\$1.178.700.00
133	63804	PROVIDENCIA No Ext: 336 No Int: 12	03100	4	2	5	600	1987	10	33.34	76.41	3	1	0	1	0	13-dic-07	3	\$957.400.00
134	63807	XOCHICALCO No Ext: 880 No Int: DEPTO AHUEHUETE 501	03310	9	1	10	840	2007	24	18.17	59.90	2	2	0	0	1	11-dic-07	3	\$967.400.00
135	63808	JOSE MA VERTIZ No Ext: 787 No Int: 201	03023	3	2	10	960	2007	28	20.31	88.10	2	1	0	2	1	18-dic-07	4	\$1.297.700.00
136	64183	ADOLFO PRIETO No Ext: 1654 No Int: 302	03100	4	2	10	816	2005	20	26.07	93.28	2	2	0	1	1	30-nov-07	3	\$1.502.700.00
137	64525	FUENTES BROTANTES No Ext: 35 No Int: BIS A 203	03570	29	2	10	840	2007	35	18.09	69.40	2	1	0	1	1	20-dic-07	3	\$978.500.00
138	64595	CERRADA DE AMORES No Ext: 27 No Int: 304	03100	4	2	10	456	1975	16	21.79	71.00	2	1	0	1	0	07-dic-07	3	\$938.600.00
139	64682	FRESAS No Ext: 122 No Int: DEPTO A-202	03100	4	2	10	480	1977	24	24.04	121.57	2	3	0	0	1	19-dic-07	3	\$1.562.200.00
140	64743	PALENQUE MZ: 248 Lte: 17 No Ext: 308 No Int: 302	03023	3	2	10	768	2001	20	20.27	77.61	2	2	0	1	0	21-dic-07	3	\$1.064.800.00
141	65744	VIADUCTO MIGUEL ALEMAN No Ext: 890 A No Int: DEPTO 307	03810	20	3	10	540	1982	36	24.00	74.85	2	1	1	1	0	19-dic-07	3	\$898.900.00
142	65770	CALLE DOS No Ext: 17 No Int: 305	03820	32	3	5	804	2004	6	39.38	89.17	2	2	0	1	0	20-dic-07	3	\$1.367.900.00
143	65909	INDIANAPOLIS No Ext: 89 No Int: DEPTO E-703	03810	20	3	10	840	2007	59	19.22	64.20	2	1	0	2	1	26-dic-07	3	\$1.194.800.00

## PREPROCESAMIENTO DE DATOS:

### 1. ANÁLISIS DE CORRELACIONES.

Se tiene un total de 15 variables:

#### V1 – LOCALIZACIÓN

Se refiere a la ubicación espacial del inmueble dentro de la Delegación. La unidad mínima espacial es el área determinada por el mismo código postal (C.P.). En la base de datos se encuentran 35 diferentes códigos postales correspondientes a 35 colonias. A cada uno de los códigos se le asignó un número, de tal suerte que a cada una de las colonias les corresponde en la base de datos un número de 1 a 35.

#### V2 – REFERENCIA DE PROXIMIDAD URBANA SHF

Se identifica en función a las principales características de ubicación municipal del inmueble valuado así como en función de su proximidad hacia el centro económico reconocido:

Céntrica (1): Zonas limitadas generalmente por vías primarias, definidas por La autoridad como zona centro.

Intermedia (2): se trata de una proximidad definida a partir de vías primarias limitadas generalmente por vialidades de velocidad intermedia.

Periférica (3): se encuentra su acceso y límite mediante vías rápidas, en la mayoría de los casos reconocida como zona urbana de crecimiento inmediato, forma parte de la ciudad.

De expansión (4): zona reconocida por la autoridad como de crecimiento potencial. En muchos casos no se encuentra definido su uso de suelo y se encuentra en proceso de reconocimiento en función de su crecimiento, próxima a ser parte de la ciudad.

Rural (5): reconocida por la autoridad como de uso agrícola o sin dotación de servicios.

#### V3 – NÚMERO DE NIVELES

Indica el número de entresijos que componen el inmueble, aplicando rangos correspondientes a lo establecido por la Tesorería del D.F.:

1 a 2 – 2  
3 a 5 – 5  
6 a 10 – 10  
11a 15 – 15  
16 a 20 – 20  
21 o más – 99

#### V4 – VIDA ÚTIL REMANENTE EN MESES

Se determina con base en la diferencia de la vida útil probable menos la edad del tipo de construcción principal.

#### V5 – AÑO DE TERMINACIÓN O REMODELACIÓN DE LA OBRA

#### V6 – UNIDADES RENTABLES GENERALES

Refleja aquellas unidades que se encuentran ligadas por la estructura en la cual se encuentra el inmueble en estudio.

#### V7 – SUPERFICIE DE TERRENO

Se refiere a la delimitación privativa del predio, ya sea marcada como propiedad individual o, tratándose de vivienda multifamiliar, como aprovechamiento del terreno calculado por medio del indiviso.

#### V8 – SUPERFICIE VENDIBLE

Se refiere a las superficies construida (área privativa de espacios del inmueble) y accesoria (terrazas, patios cubiertos, cuartos de servicio, estacionamientos cubiertos)

#### V9 – NÚMERO DE RECAMARAS

#### V10 – NÚMERO DE BAÑOS

#### V11 – NÚMERO DE MEDIOS BAÑOS

V12 – NÚMERO DE ESPACIOS DE ESTACIONAMIENTO

V13 – ELEVADOR

V14 – FECHA DEL AVALÚO

V15 – CLASE DE LA CONSTRUCCIÓN

F- VALOR CONCLUIDO

Análisis de correlaciones:

Se considera como altamente correlacionadas las variables que presentan el grado de correlación mayor que 0.75.

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	V12	V13	V14	V15	F
V1	1	0,313	-0,04	0,126	0,143	0,019	-0,05	-0,09	-0,07	-0,03	0,135	-0,02	-0,03	-0,15	-0,02	-0,05
V2	0,313	1	0,153	0,223	0,171	0,039	-0,08	0,135	-0,01	0,002	0,188	0,108	0,094	-0,12	0,288	0,212
V3	-0,04	0,153	1	0,221	0,181	0,335	-0,52	0,009	-0,06	-0	-0,11	-0,01	0,519	0,137	0,243	0,074
V4	0,126	0,223	0,221	1	0,974	0,088	0,047	0,016	0,123	0,273	-0,04	0,472	0,431	-0,01	0,5	0,398
V5	0,143	0,171	0,181	0,974	1	0,052	-0,03	-0,12	0,046	0,18	-0,12	0,409	0,41	0,007	0,29	0,253
V6	0,019	0,039	0,335	0,088	0,052	1	-0,12	0,016	-0,08	0,086	-0,01	-0,02	0,209	0,061	0,17	0,033
V7	-0,05	-0,08	-0,52	0,047	-0,03	-0,12	1	0,646	0,498	0,517	0,301	0,383	-0,25	-0,12	0,302	0,63
V8	-0,09	0,135	0,009	0,016	-0,12	0,016	0,646	1	0,567	0,668	0,353	0,397	0,123	-0,07	0,541	0,85
V9	-0,07	-0,01	-0,06	0,123	0,046	-0,08	0,498	0,567	1	0,427	0,138	0,317	0,018	-0,02	0,343	0,529
V10	-0,03	0,002	-0	0,273	0,18	0,086	0,517	0,668	0,427	1	0,125	0,415	0,225	0,026	0,462	0,702
V11	0,135	0,188	-0,11	-0,04	-0,12	-0,01	0,301	0,353	0,138	0,125	1	0,13	-0,09	-0,03	0,261	0,331
V12	-0,02	0,108	-0,01	0,472	0,409	-0,02	0,383	0,397	0,317	0,415	0,13	1	0,248	-0,08	0,428	0,614
V13	-0,03	0,094	0,519	0,431	0,41	0,209	-0,25	0,123	0,018	0,225	-0,09	0,248	1	0,047	0,255	0,265
V14	-0,15	-0,12	0,137	-0,01	0,007	0,061	-0,12	-0,07	-0,02	0,026	-0,03	-0,08	0,047	1	-0,06	-0,06
V15	-0,02	0,288	0,243	0,5	0,29	0,17	0,302	0,541	0,343	0,462	0,261	0,428	0,255	-0,06	1	0,711
F	-0,05	0,212	0,074	0,398	0,253	0,033	0,63	0,85	0,529	0,702	0,331	0,614	0,265	-0,06	0,711	1

Del análisis de correlaciones resultó que las variables V4 (vida útil remanente) y la variable V5 (año de terminación de obra) están altamente correlacionadas entre sí, por lo que se procede con la eliminación de la variable V5. Mientras que la variable V8 (superficie vendible) se eliminará por estar altamente correlacionada con la variable dependiente (F – valor concluido).

Base de datos sin variables correlacionadas:

	V1	V2	V3	V4	V6	V7	V9	V10	V11	V12	V13	V14	V15	F
1	34	3	5	840	3	31,3075	1	1	0	1	0	122,0000	3	937200,0000
2	27	2	5	480	14	30,5339	2	1	0	1	0	128,0000	3	1140900,0000
3	20	3	15	960	17	29,0150	3	3	0	2	1	127,0000	4	2591600,0000
4	8	2	5	816	9	46,6200	3	2	0	2	0	132,0000	3	1416900,0000
5	34	3	5	360	6	36,2883	2	1	0	0	0	171,0000	3	618400,0000
6	11	2	10	840	24	14,1985	2	1	0	0	1	132,0000	3	643300,0000
7	12	2	5	360	2	47,5396	2	1	0	0	0	142,0000	2	531400,0000
8	4	2	10	840	3	22,7106	2	1	0	2	1	133,0000	3	1228400,0000
9	22	3	10	780	30	15,9997	2	1	0	1	0	139,0000	3	840000,0000
10	19	2	10	840	4	19,8251	2	2	0	1	1	139,0000	3	927600,0000
11	9	1	10	840	21	17,7458	2	1	0	1	1	122,0000	3	925800,0000
12	13	2	10	840	44	16,3935	2	1	0	1	1	141,0000	3	808800,0000
13	16	2	10	840	28	16,6140	2	1	0	1	1	161,0000	3	744500,0000
14	10	2	5	960	12	75,5668	3	3	0	2	0	155,0000	4	2178500,0000
15	10	2	5	960	12	75,5668	3	3	0	2	0	156,0000	4	2166000,0000
16	12	2	10	840	60	13,6243	2	1	0	1	0	230,0000	3	650300,0000
17	14	2	10	840	15	13,2036	2	1	0	0	0	153,0000	3	731600,0000
18	4	2	5	420	12	29,1750	3	1	0	0	0	162,0000	3	855900,0000
19	13	2	10	840	44	16,6885	2	1	0	1	0	161,0000	3	794100,0000
20	15	2	10	840	27	17,9444	2	1	0	1	0	168,0000	3	887200,0000
21	20	3	10	840	75	18,4994	2	1	0	1	1	293,0000	3	1114600,0000
22	15	2	5	684	10	34,8494	2	1	0	2	0	183,0000	3	820300,0000
23	34	3	10	840	18	16,0245	2	1	0	1	0	183,0000	3	891700,0000
24	20	3	5	828	8	30,1600	2	2	0	2	0	182,0000	3	1882400,0000
25	6	3	5	948	14	35,4654	2	2	0	2	1	183,0000	4	1913900,0000
26	2	2	5	408	140	53,0341	2	3	0	1	0	184,0000	3	1116000,0000
27	20	3	10	840	10	19,7100	2	2	0	2	1	175,0000	3	1711000,0000
28	1	2	5	600	10	28,8704	3	1	0	1	0	188,0000	3	743900,0000
29	17	2	5	828	8	27,2071	2	2	0	1	0	204,0000	3	771200,0000
30	20	3	10	960	35	28,1400	3	2	0	2	1	185,0000	4	1819800,0000
31	20	3	5	804	7	34,1252	2	1	0	1	0	185,0000	3	1391500,0000
32	18	3	5	840	15	33,1200	3	2	0	2	1	189,0000	3	1449500,0000
33	5	2	10	504	17	23,5586	2	2	0	1	0	195,0000	3	1067800,0000
34	21	3	10	708	14	22,4464	2	2	1	1	1	202,0000	4	1747200,0000
35	27	2	10	480	12	22,1240	2	1	0	1	0	195,0000	3	913500,0000
36	7	1	10	384	16	20,5896	2	1	0	1	1	199,0000	3	984900,0000
37	3	2	5	360	16	13,5001	2	1	0	0	0	196,0000	3	709100,0000
38	20	3	10	960	17	28,4843	2	2	0	2	1	204,0000	4	2054000,0000
39	33	3	10	960	17	45,1367	3	3	1	2	1	202,0000	4	2756300,0000
40	21	3	10	600	10	24,5200	3	1	0	1	0	213,0000	3	1188300,0000
41	32	3	15	960	23	20,2930	3	2	0	1	1	223,0000	4	1405200,0000

42	20	3	5	840	8	31,5840	2	2	1	1	1	218,0000	3	1599800,0000
43	12	2	10	840	20	29,1028	3	2	0	2	1	321,0000	3	1235600,0000
44	4	2	5	240	13	18,0163	2	1	0	0	0	239,0000	2	472900,0000
45	9	1	5	420	25	14,6000	2	1	0	0	0	212,0000	3	500000,0000
46	23	3	5	396	8	34,8443	3	2	0	0	0	204,0000	3	1223500,0000
47	8	2	10	840	15	20,7897	2	2	0	1	1	289,0000	3	1109100,0000
48	20	3	10	936	23	22,1792	2	2	0	1	1	205,0000	4	1342300,0000
49	12	2	10	840	20	29,1028	3	2	0	2	1	205,0000	3	1281100,0000
50	28	2	5	816	3	47,3033	2	2	0	1	0	262,0000	3	1243800,0000
51	16	2	10	840	20	25,3080	2	2	0	1	1	262,0000	3	1138200,0000
52	3	2	5	840	7	65,1341	3	2	0	1	0	244,0000	3	1774200,0000
53	18	3	10	840	20	16,0654	2	2	0	1	1	294,0000	3	886300,0000
54	26	1	5	912	66	63,6400	3	3	1	2	0	222,0000	4	2160000,0000
55	26	1	5	840	28	37,4000	2	2	0	2	0	232,0000	3	1420000,0000
56	13	2	10	840	44	16,5716	2	1	0	1	1	244,0000	3	789800,0000
57	15	2	10	840	15	18,5333	2	1	0	1	1	294,0000	3	809400,0000
58	15	2	10	840	15	17,4207	2	1	0	1	1	238,0000	3	774100,0000
59	16	2	10	840	28	16,6140	2	1	0	1	1	262,0000	3	783500,0000
60	1	2	10	840	15	13,2646	2	1	0	0	1	324,0000	3	636400,0000
61	8	2	5	840	6	35,8260	2	2	0	1	0	245,0000	3	994500,0000
62	4	2	5	804	3	58,3864	3	2	0	2	1	254,0000	3	2109000,0000
63	8	2	10	0	15	24,4815	3	2	0	1	0	253,0000	3	1327700,0000
64	13	2	10	444	9	18,8851	2	1	0	0	0	253,0000	3	556400,0000
65	30	1	5	276	6	26,6656	2	1	0	1	0	258,0000	2	524400,0000
66	8	2	5	540	16	16,9728	2	1	0	1	0	258,0000	3	585800,0000
67	27	2	10	840	22	19,8811	3	2	0	1	1	283,0000	3	892400,0000
68	3	2	5	732	4	40,3075	2	2	0	1	0	261,0000	3	1016900,0000
69	31	2	10	840	20	27,3540	3	2	0	2	0	259,0000	3	1725000,0000
70	26	1	5	468	13	23,4878	2	1	0	1	0	267,0000	3	793700,0000
71	28	2	5	840	28	16,7747	2	2	0	1	1	268,0000	3	816200,0000
72	35	3	5	504	10	30,2312	2	1	1	1	0	268,0000	3	960600,0000
73	19	2	5	840	14	26,7732	2	2	0	2	1	272,0000	3	1182300,0000
74	4	2	5	960	5	49,6280	3	2	0	2	1	272,0000	4	2147600,0000
75	27	2	10	840	22	17,4983	2	2	0	1	1	296,0000	3	955400,0000
76	12	2	5	336	14	13,9684	1	1	0	0	0	268,0000	3	384700,0000
77	19	2	5	840	14	28,4741	2	2	0	1	1	293,0000	3	1183800,0000
78	20	3	5	600	16	33,8097	3	1	1	0	0	268,0000	3	1076600,0000
79	3	2	10	840	20	14,6615	2	1	0	1	1	268,0000	3	887800,0000
80	28	2	5	840	3	42,4996	3	2	0	1	0	296,0000	3	1224800,0000
81	3	2	10	840	15	15,1334	2	1	0	1	0	288,0000	3	778100,0000
82	27	2	10	840	32	13,5000	2	1	0	0	1	307,0000	3	702500,0000
83	19	2	5	408	10	30,7000	2	1	0	1	0	279,0000	3	760100,0000
84	4	2	10	600	10	50,8907	3	3	1	2	0	279,0000	4	2523600,0000
85	4	2	10	840	21	22,5796	2	2	0	2	1	279,0000	3	1699200,0000
86	4	2	10	396	14	64,2677	3	2	0	2	1	307,0000	3	2172100,0000
87	20	3	10	960	10	26,2720	2	2	0	2	1	289,0000	4	1589100,0000

88	4	2	5	600	9	34,6531	2	1	0	0	0	295,0000	3	991800,0000
89	12	2	10	840	15	16,6650	2	1	0	1	1	351,0000	3	729000,0000
90	19	2	10	828	14	20,4728	3	1	0	1	0	303,0000	3	1075000,0000
91	2	2	5	360	3	44,9018	2	1	1	2	0	307,0000	3	1005600,0000
92	8	2	5	840	3	31,5630	2	1	0	1	0	307,0000	3	882900,0000
93	8	2	5	840	3	44,7720	2	2	0	1	0	309,0000	3	1146500,0000
94	27	2	10	840	22	17,5368	2	2	0	1	1	307,0000	3	955400,0000
95	4	2	10	384	52	30,8664	2	3	0	1	1	321,0000	3	1392000,0000
96	8	2	5	840	11	31,4160	2	2	0	1	0	322,0000	3	1059400,0000
97	4	2	10	960	64	29,4021	3	2	0	1	1	321,0000	4	1965800,0000
98	8	2	5	840	16	34,3886	3	2	0	2	0	335,0000	3	1107200,0000
99	24	1	10	840	40	44,9189	2	2	0	2	1	328,0000	3	1647000,0000
100	8	2	5	840	11	42,0420	2	2	0	1	0	322,0000	3	1242800,0000
101	4	2	10	960	5	40,5484	3	3	0	2	1	340,0000	4	2482000,0000
102	10	2	5	960	12	84,3126	3	2	1	2	0	352,0000	4	3070400,0000
103	19	2	5	480	25	32,1812	2	1	0	0	0	384,0000	3	762700,0000
104	8	2	10	840	15	22,9786	3	2	0	0	1	351,0000	3	1303400,0000
105	25	2	10	840	10	23,5170	2	2	0	1	1	351,0000	3	1338800,0000
106	21	3	15	960	147	19,2779	2	2	0	1	1	346,0000	4	1698000,0000
107	4	2	10	456	16	23,9800	2	1	0	0	0	352,0000	3	750600,0000
108	8	2	10	396	16	19,9408	2	2	0	1	0	353,0000	3	771000,0000
109	19	2	10	840	20	20,0134	2	2	0	1	1	384,0000	3	842600,0000
110	4	2	10	504	14	20,5176	2	2	0	0	0	371,0000	3	1312300,0000
111	4	2	10	840	10	17,6571	2	2	0	1	1	377,0000	3	1184500,0000
112	4	2	10	528	20	22,7627	3	2	0	2	1	414,0000	3	1274400,0000
113	5	2	10	504	10	15,1200	1	1	0	1	0	384,0000	3	602900,0000
114	12	2	10	828	20	14,7010	2	1	0	0	0	421,0000	3	570200,0000
115	30	1	5	408	20	51,6811	3	3	0	0	0	384,0000	3	1093500,0000
116	29	2	5	372	10	24,7197	2	1	0	0	0	379,0000	2	326700,0000
117	3	2	10	840	28	20,9068	2	2	0	1	1	387,0000	3	1207900,0000
118	32	3	10	840	30	16,5717	2	1	0	1	0	393,0000	3	616400,0000
119	19	2	5	480	25	44,5817	3	1	0	0	0	401,0000	3	1125800,0000
120	4	2	15	504	40	11,8200	2	1	0	0	1	400,0000	3	883300,0000
121	8	2	5	840	8	29,5250	2	1	0	2	0	399,0000	3	950200,0000
122	16	2	10	768	24	11,0830	2	1	0	0	0	409,0000	3	574800,0000
123	21	3	10	840	36	12,9987	1	1	0	1	1	436,0000	3	1146400,0000
124	4	2	10	960	23	33,5947	3	2	0	2	1	420,0000	4	1837300,0000
125	3	2	10	840	29	22,9561	3	2	0	2	1	422,0000	3	1559000,0000
126	27	2	5	840	8	26,2185	2	2	0	1	0	415,0000	3	970400,0000
127	4	2	10	480	13	18,5896	2	1	0	0	0	420,0000	3	1083300,0000
128	8	2	10	768	20	13,1250	2	1	0	1	0	421,0000	3	610700,0000
129	20	3	10	960	10	30,7800	3	2	0	1	0	422,0000	4	1585900,0000
130	8	2	5	840	8	32,7511	3	2	0	2	0	420,0000	3	1043900,0000
131	8	2	5	840	8	32,2681	2	2	0	2	0	420,0000	3	1043900,0000
132	19	2	5	816	8	32,6085	3	2	0	2	1	433,0000	3	1178700,0000
133	4	2	5	600	10	33,3440	3	1	0	1	0	429,0000	3	957400,0000

134	9	1	10	840	24	18,1680	2	2	0	0	1	427,0000	3	967400,0000
135	3	2	10	960	28	20,3134	2	1	0	2	1	434,0000	4	1297700,0000
136	4	2	10	816	20	26,0736	2	2	0	1	1	416,0000	3	1502700,0000
137	29	2	10	840	35	18,0889	2	1	0	1	1	436,0000	3	978500,0000
138	4	2	10	456	16	21,7920	2	1	0	1	0	423,0000	3	938600,0000
139	4	2	10	480	24	24,0400	2	3	0	0	1	435,0000	3	1562200,0000
140	3	2	10	768	20	20,2654	2	2	0	1	0	437,0000	3	1064800,0000
141	20	3	10	540	36	24,0003	2	1	1	1	0	435,0000	3	898900,0000
142	32	3	5	804	6	39,3756	2	2	0	1	0	436,0000	3	1367900,0000
143	20	3	10	840	59	19,2155	2	1	0	2	1	442,0000	3	1194800,0000

## 2. NORMALIZACIÓN.

Se procede a la normalización de valores de la base de datos sin variables correlacionadas.

	V1	V2	V3	V4	V6	V7	V9	V10	V11	V12	V13	V14	V15	F
1	0,9706	1	0	0,875	0,0069	0,2762	0	0	0	0,5	0	0	0,5	0,2225
2	0,7647	0,5	0	0,5	0,0828	0,2656	0,5	0	0	0,5	0	0,0188	0,5	0,2968
3	0,5588	1	1	1	0,1034	0,2449	1	1	0	1	1	0,0156	1	0,8255
4	0,2059	0,5	0	0,85	0,0483	0,4853	1	0,5	0	1	0	0,0313	0,5	0,3973
5	0,9706	1	0	0,375	0,0276	0,3442	0,5	0	0	0	0	0,1531	0,5	0,1063
6	0,2941	0,5	0,5	0,875	0,1517	0,0425	0,5	0	0	0	1	0,0313	0,5	0,1154
7	0,3235	0,5	0	0,375	0	0,4978	0,5	0	0	0	0	0,0625	0	0,0746
8	0,0882	0,5	0,5	0,875	0,0069	0,1588	0,5	0	0	1	1	0,0344	0,5	0,3286
9	0,6176	1	0,5	0,8125	0,1931	0,0671	0,5	0	0	0,5	0	0,0531	0,5	0,1871
10	0,5294	0,5	0,5	0,875	0,0138	0,1194	0,5	0,5	0	0,5	1	0,0531	0,5	0,219
11	0,2353	0	0,5	0,875	0,131	0,091	0,5	0	0	0,5	1	0	0,5	0,2184
12	0,3529	0,5	0,5	0,875	0,2897	0,0725	0,5	0	0	0,5	1	0,0594	0,5	0,1757
13	0,4412	0,5	0,5	0,875	0,1793	0,0755	0,5	0	0	0,5	1	0,1219	0,5	0,1523
14	0,2647	0,5	0	1	0,069	0,8806	1	1	0	1	0	0,1031	1	0,6749
15	0,2647	0,5	0	1	0,069	0,8806	1	1	0	1	0	0,1063	1	0,6704
16	0,3235	0,5	0,5	0,875	0,4	0,0347	0,5	0	0	0,5	0	0,3375	0,5	0,1179
17	0,3824	0,5	0,5	0,875	0,0897	0,029	0,5	0	0	0	0	0,0969	0,5	0,1476
18	0,0882	0,5	0	0,4375	0,069	0,2471	1	0	0	0	0	0,125	0,5	0,1929
19	0,3529	0,5	0,5	0,875	0,2897	0,0765	0,5	0	0	0,5	0	0,1219	0,5	0,1704
20	0,4118	0,5	0,5	0,875	0,1724	0,0937	0,5	0	0	0,5	0	0,1438	0,5	0,2043
21	0,5588	1	0,5	0,875	0,5034	0,1013	0,5	0	0	0,5	1	0,5344	0,5	0,2872
22	0,4118	0,5	0	0,7125	0,0552	0,3245	0,5	0	0	1	0	0,1906	0,5	0,1799
23	0,9706	1	0,5	0,875	0,1103	0,0675	0,5	0	0	0,5	0	0,1906	0,5	0,2059
24	0,5588	1	0	0,8625	0,0414	0,2605	0,5	0,5	0	1	0	0,1875	0,5	0,567
25	0,1471	1	0	0,9875	0,0828	0,333	0,5	0,5	0	1	1	0,1906	1	0,5785
26	0,0294	0,5	0	0,425	0,9517	0,5729	0,5	1	0	0,5	0	0,1938	0,5	0,2877
27	0,5588	1	0,5	0,875	0,0552	0,1178	0,5	0,5	0	1	1	0,1656	0,5	0,5045

28	0	0,5	0	0,625	0,0552	0,2429	1	0	0	0,5	0	0,2063	0,5	0,1521
29	0,4706	0,5	0	0,8625	0,0414	0,2202	0,5	0,5	0	0,5	0	0,2563	0,5	0,162
30	0,5588	1	0,5	1	0,2276	0,2329	1	0,5	0	1	1	0,1969	1	0,5442
31	0,5588	1	0	0,8375	0,0345	0,3147	0,5	0	0	0,5	0	0,1969	0,5	0,3881
32	0,5	1	0	0,875	0,0897	0,3009	1	0,5	0	1	1	0,2094	0,5	0,4092
33	0,1176	0,5	0,5	0,525	0,1034	0,1704	0,5	0,5	0	0,5	0	0,2281	0,5	0,2701
34	0,5882	1	0,5	0,7375	0,0828	0,1552	0,5	0,5	1	0,5	1	0,25	1	0,5177
35	0,7647	0,5	0,5	0,5	0,069	0,1508	0,5	0	0	0,5	0	0,2281	0,5	0,2139
36	0,1765	0	0,5	0,4	0,0966	0,1298	0,5	0	0	0,5	1	0,2406	0,5	0,2399
37	0,0588	0,5	0	0,375	0,0966	0,033	0,5	0	0	0	0	0,2313	0,5	0,1394
38	0,5588	1	0,5	1	0,1034	0,2376	0,5	0,5	0	1	1	0,2563	1	0,6296
39	0,9412	1	0,5	1	0,1034	0,465	1	1	1	1	1	0,25	1	0,8855
40	0,5882	1	0,5	0,625	0,0552	0,1835	1	0	0	0,5	0	0,2844	0,5	0,314
41	0,9118	1	1	1	0,1448	0,1258	1	0,5	0	0,5	1	0,3156	1	0,3931
42	0,5588	1	0	0,875	0,0414	0,28	0,5	0,5	1	0,5	1	0,3	0,5	0,464
43	0,3235	0,5	0,5	0,875	0,1241	0,2461	1	0,5	0	1	1	0,6219	0,5	0,3313
44	0,0882	0,5	0	0,25	0,0759	0,0947	0,5	0	0	0	0	0,3656	0	0,0533
45	0,2353	0	0	0,4375	0,1586	0,048	0,5	0	0	0	0	0,2813	0,5	0,0632
46	0,6471	1	0	0,4125	0,0414	0,3245	1	0,5	0	0	0	0,2563	0,5	0,3269
47	0,2059	0,5	0,5	0,875	0,0897	0,1326	0,5	0,5	0	0,5	1	0,5219	0,5	0,2852
48	0,5588	1	0,5	0,975	0,1448	0,1515	0,5	0,5	0	0,5	1	0,2594	1	0,3702
49	0,3235	0,5	0,5	0,875	0,1241	0,2461	1	0,5	0	1	1	0,2594	0,5	0,3479
50	0,7941	0,5	0	0,85	0,0069	0,4946	0,5	0,5	0	0,5	0	0,4375	0,5	0,3343
51	0,4412	0,5	0,5	0,875	0,1241	0,1943	0,5	0,5	0	0,5	1	0,4375	0,5	0,2958
52	0,0588	0,5	0	0,875	0,0345	0,7381	1	0,5	0	0,5	0	0,3813	0,5	0,5276
53	0,5	1	0,5	0,875	0,1241	0,068	0,5	0,5	0	0,5	1	0,5375	0,5	0,204
54	0,7353	0	0	0,95	0,4414	0,7177	1	1	1	1	0	0,3125	1	0,6682
55	0,7353	0	0	0,875	0,1793	0,3594	0,5	0,5	0	1	0	0,3438	0,5	0,3985
56	0,3529	0,5	0,5	0,875	0,2897	0,075	0,5	0	0	0,5	1	0,3813	0,5	0,1688
57	0,4118	0,5	0,5	0,875	0,0897	0,1017	0,5	0	0	0,5	1	0,5375	0,5	0,1759
58	0,4118	0,5	0,5	0,875	0,0897	0,0865	0,5	0	0	0,5	1	0,3625	0,5	0,1631
59	0,4412	0,5	0,5	0,875	0,1793	0,0755	0,5	0	0	0,5	1	0,4375	0,5	0,1665
60	0	0,5	0,5	0,875	0,0897	0,0298	0,5	0	0	0	1	0,6313	0,5	0,1129
61	0,2059	0,5	0	0,875	0,0276	0,3379	0,5	0,5	0	0,5	0	0,3844	0,5	0,2434
62	0,0882	0,5	0	0,8375	0,0069	0,646	1	0,5	0	1	1	0,4125	0,5	0,6496
63	0,2059	0,5	0,5	0	0,0897	0,183	1	0,5	0	0,5	0	0,4094	0,5	0,3648
64	0,3529	0,5	0,5	0,4625	0,0483	0,1065	0,5	0	0	0	0	0,4094	0,5	0,0837
65	0,8529	0	0	0,2875	0,0276	0,2128	0,5	0	0	0,5	0	0,425	0	0,0721
66	0,2059	0,5	0	0,5625	0,0966	0,0804	0,5	0	0	0,5	0	0,425	0,5	0,0944
67	0,7647	0,5	0,5	0,875	0,1379	0,1201	1	0,5	0	0,5	1	0,5031	0,5	0,2062
68	0,0588	0,5	0	0,7625	0,0138	0,3991	0,5	0,5	0	0,5	0	0,4344	0,5	0,2516
69	0,8824	0,5	0,5	0,875	0,1241	0,2222	1	0,5	0	1	0	0,4281	0,5	0,5096
70	0,7353	0	0	0,4875	0,0759	0,1694	0,5	0	0	0,5	0	0,4531	0,5	0,1702
71	0,7941	0,5	0	0,875	0,1793	0,0777	0,5	0,5	0	0,5	1	0,4563	0,5	0,1784
72	1	1	0	0,525	0,0552	0,2615	0,5	0	1	0,5	0	0,4563	0,5	0,231
73	0,5294	0,5	0	0,875	0,0828	0,2143	0,5	0,5	0	1	1	0,4688	0,5	0,3118

74	0,0882	0,5	0	1	0,0207	0,5264	1	0,5	0	1	1	0,4688	1	0,6637
75	0,7647	0,5	0,5	0,875	0,1379	0,0876	0,5	0,5	0	0,5	1	0,5438	0,5	0,2291
76	0,3235	0,5	0	0,35	0,0828	0,0394	0	0	0	0	0	0,4563	0,5	0,0211
77	0,5294	0,5	0	0,875	0,0828	0,2375	0,5	0,5	0	0,5	1	0,5344	0,5	0,3124
78	0,5588	1	0	0,625	0,0966	0,3103	1	0	1	0	0	0,4563	0,5	0,2733
79	0,0588	0,5	0,5	0,875	0,1241	0,0489	0,5	0	0	0,5	1	0,4563	0,5	0,2045
80	0,7941	0,5	0	0,875	0,0069	0,429	1	0,5	0	0,5	0	0,5438	0,5	0,3273
81	0,0588	0,5	0,5	0,875	0,0897	0,0553	0,5	0	0	0,5	0	0,5188	0,5	0,1645
82	0,7647	0,5	0,5	0,875	0,2069	0,033	0,5	0	0	0	1	0,5781	0,5	0,137
83	0,5294	0,5	0	0,425	0,0552	0,2679	0,5	0	0	0,5	0	0,4906	0,5	0,158
84	0,0882	0,5	0,5	0,625	0,0552	0,5436	1	1	1	1	0	0,4906	1	0,8007
85	0,0882	0,5	0,5	0,875	0,131	0,157	0,5	0,5	0	1	1	0,4906	0,5	0,5002
86	0,0882	0,5	0,5	0,4125	0,0828	0,7263	1	0,5	0	1	1	0,5781	0,5	0,6726
87	0,5588	1	0,5	1	0,0552	0,2074	0,5	0,5	0	1	1	0,5219	1	0,4601
88	0,0882	0,5	0	0,625	0,0483	0,3219	0,5	0	0	0	0	0,5406	0,5	0,2424
89	0,3235	0,5	0,5	0,875	0,0897	0,0762	0,5	0	0	0,5	1	0,7156	0,5	0,1466
90	0,5294	0,5	0,5	0,8625	0,0828	0,1282	1	0	0	0,5	0	0,5656	0,5	0,2727
91	0,0294	0,5	0	0,375	0,0069	0,4618	0,5	0	1	1	0	0,5781	0,5	0,2474
92	0,2059	0,5	0	0,875	0,0069	0,2797	0,5	0	0	0,5	0	0,5781	0,5	0,2027
93	0,2059	0,5	0	0,875	0,0069	0,46	0,5	0,5	0	0,5	0	0,5844	0,5	0,2988
94	0,7647	0,5	0,5	0,875	0,1379	0,0881	0,5	0,5	0	0,5	1	0,5781	0,5	0,2291
95	0,0882	0,5	0,5	0,4	0,3448	0,2702	0,5	1	0	0,5	1	0,6219	0,5	0,3883
96	0,2059	0,5	0	0,875	0,0621	0,2777	0,5	0,5	0	0,5	0	0,625	0,5	0,267
97	0,0882	0,5	0,5	1	0,4276	0,2502	1	0,5	0	0,5	1	0,6219	1	0,5974
98	0,2059	0,5	0	0,875	0,0966	0,3183	1	0,5	0	1	0	0,6656	0,5	0,2845
99	0,6765	0	0,5	0,875	0,2621	0,4621	0,5	0,5	0	1	1	0,6438	0,5	0,4812
100	0,2059	0,5	0	0,875	0,0621	0,4228	0,5	0,5	0	0,5	0	0,625	0,5	0,3339
101	0,0882	0,5	0,5	1	0,0207	0,4024	1	1	0	1	1	0,6813	1	0,7855
102	0,2647	0,5	0	1	0,069	1	1	0,5	1	1	0	0,7188	1	1
103	0,5294	0,5	0	0,5	0,1586	0,2881	0,5	0	0	0	0	0,8188	0,5	0,1589
104	0,2059	0,5	0,5	0,875	0,0897	0,1624	1	0,5	0	0	1	0,7156	0,5	0,356
105	0,7059	0,5	0,5	0,875	0,0552	0,1698	0,5	0,5	0	0,5	1	0,7156	0,5	0,3689
106	0,5882	1	1	1	1	0,1119	0,5	0,5	0	0,5	1	0,7	1	0,4998
107	0,0882	0,5	0,5	0,475	0,0966	0,1761	0,5	0	0	0	0	0,7188	0,5	0,1545
108	0,2059	0,5	0,5	0,4125	0,0966	0,121	0,5	0,5	0	0,5	0	0,7219	0,5	0,1619
109	0,5294	0,5	0,5	0,875	0,1241	0,122	0,5	0,5	0	0,5	1	0,8188	0,5	0,188
110	0,0882	0,5	0,5	0,525	0,0828	0,1288	0,5	0,5	0	0	0	0,7781	0,5	0,3592
111	0,0882	0,5	0,5	0,875	0,0552	0,0898	0,5	0,5	0	0,5	1	0,7969	0,5	0,3126
112	0,0882	0,5	0,5	0,55	0,1241	0,1595	1	0,5	0	1	1	0,9125	0,5	0,3454
113	0,1176	0,5	0,5	0,525	0,0552	0,0551	0	0	0	0,5	0	0,8188	0,5	0,1007
114	0,3235	0,5	0,5	0,8625	0,1241	0,0494	0,5	0	0	0	0	0,9344	0,5	0,0887
115	0,8529	0	0	0,425	0,1241	0,5544	1	1	0	0	0	0,8188	0,5	0,2795
116	0,8235	0,5	0	0,3875	0,0552	0,1862	0,5	0	0	0	0	0,8031	0	0
117	0,0588	0,5	0,5	0,875	0,1793	0,1342	0,5	0,5	0	0,5	1	0,8281	0,5	0,3212
118	0,9118	1	0,5	0,875	0,1931	0,075	0,5	0	0	0,5	0	0,8469	0,5	0,1056
119	0,5294	0,5	0	0,5	0,1586	0,4574	1	0	0	0	0	0,8719	0,5	0,2912

120	0,0882	0,5	1	0,525	0,2621	0,0101	0,5	0	0	0	1	0,8688	0,5	0,2029
121	0,2059	0,5	0	0,875	0,0414	0,2518	0,5	0	0	1	0	0,8656	0,5	0,2272
122	0,4412	0,5	0,5	0,8	0,1517	0	0,5	0	0	0	0	0,8969	0,5	0,0904
123	0,5882	1	0,5	0,875	0,2345	0,0262	0	0	0	0,5	1	0,9813	0,5	0,2988
124	0,0882	0,5	0,5	1	0,1448	0,3074	1	0,5	0	1	1	0,9313	1	0,5506
125	0,0588	0,5	0,5	0,875	0,1862	0,1621	1	0,5	0	1	1	0,9375	0,5	0,4491
126	0,7647	0,5	0	0,875	0,0414	0,2067	0,5	0,5	0	0,5	0	0,9156	0,5	0,2346
127	0,0882	0,5	0,5	0,5	0,0759	0,1025	0,5	0	0	0	0	0,9313	0,5	0,2758
128	0,2059	0,5	0,5	0,8	0,1241	0,0279	0,5	0	0	0,5	0	0,9344	0,5	0,1035
129	0,5588	1	0,5	1	0,0552	0,269	1	0,5	0	0,5	0	0,9375	1	0,4589
130	0,2059	0,5	0	0,875	0,0414	0,2959	1	0,5	0	1	0	0,9313	0,5	0,2614
131	0,2059	0,5	0	0,875	0,0414	0,2893	0,5	0,5	0	1	0	0,9313	0,5	0,2614
132	0,5294	0,5	0	0,85	0,0414	0,2939	1	0,5	0	1	1	0,9719	0,5	0,3105
133	0,0882	0,5	0	0,625	0,0552	0,304	1	0	0	0,5	0	0,9594	0,5	0,2299
134	0,2353	0	0,5	0,875	0,1517	0,0968	0,5	0,5	0	0	1	0,9531	0,5	0,2335
135	0,0588	0,5	0,5	1	0,1793	0,126	0,5	0	0	1	1	0,975	1	0,3539
136	0,0882	0,5	0,5	0,85	0,1241	0,2047	0,5	0,5	0	0,5	1	0,9188	0,5	0,4286
137	0,8235	0,5	0,5	0,875	0,2276	0,0957	0,5	0	0	0,5	1	0,9813	0,5	0,2376
138	0,0882	0,5	0,5	0,475	0,0966	0,1462	0,5	0	0	0,5	0	0,9406	0,5	0,223
139	0,0882	0,5	0,5	0,5	0,1517	0,1769	0,5	1	0	0	1	0,9781	0,5	0,4503
140	0,0588	0,5	0,5	0,8	0,1241	0,1254	0,5	0,5	0	0,5	0	0,9844	0,5	0,269
141	0,5588	1	0,5	0,5625	0,2345	0,1764	0,5	0	1	0,5	0	0,9781	0,5	0,2086
142	0,9118	1	0	0,8375	0,0276	0,3864	0,5	0,5	0	0,5	0	0,9813	0,5	0,3795
143	0,5588	1	0,5	0,875	0,3931	0,1111	0,5	0	0	1	1	1	0,5	0,3164

### 3. ANÁLISIS DE DENSIDAD DE DATOS.

La base de datos no presenta problemas de densidad, se trata de departamentos nuevos y usados valuados en el lapso de un año, con características similares y ubicación correspondiente a la Delegación Benito Juárez.

#### ARQUITECTURA DE LA RED.

La arquitectura de la red está dictada por el n° de entradas, el n° de salidas, el número de capas ocultas y el n° de conexiones.

Aplicando la fórmula para el n° de neuronas en la capa oculta obtenemos:

$$H = [(S/3)-O] / (I+1+O)$$

I – nº de neuronas de entrada (input) = 13

O – nº de neuronas de salida (output) = 1

C – número de conexiones entre neuronas que debe equivaler a la tercera parte de la muestra; si su número es mayor se corre el riesgo de que la red aprenda de memoria. ( $C \approx S/3$ , S – nº de elementos de la muestra training,  $C \approx 112/3 = 37.3$ )

H – el nº de neuronas de la capa oculta

$$H = [(37.3333-1) / (13+1+1)] = 2.42$$

Se entrenará primero una red con la arquitectura de 2 neuronas en la capa oculta y posteriormente una red con 3 neuronas en la capa oculta. La red que tendrá menor error de prueba (TEST ERROR) será la más indicada.

The image displays two side-by-side screenshots of a neural network configuration interface, likely from a software like NeuroLab. Both screenshots show the configuration for a neural network named 'HIDDEN AGA\_2.mlp'.

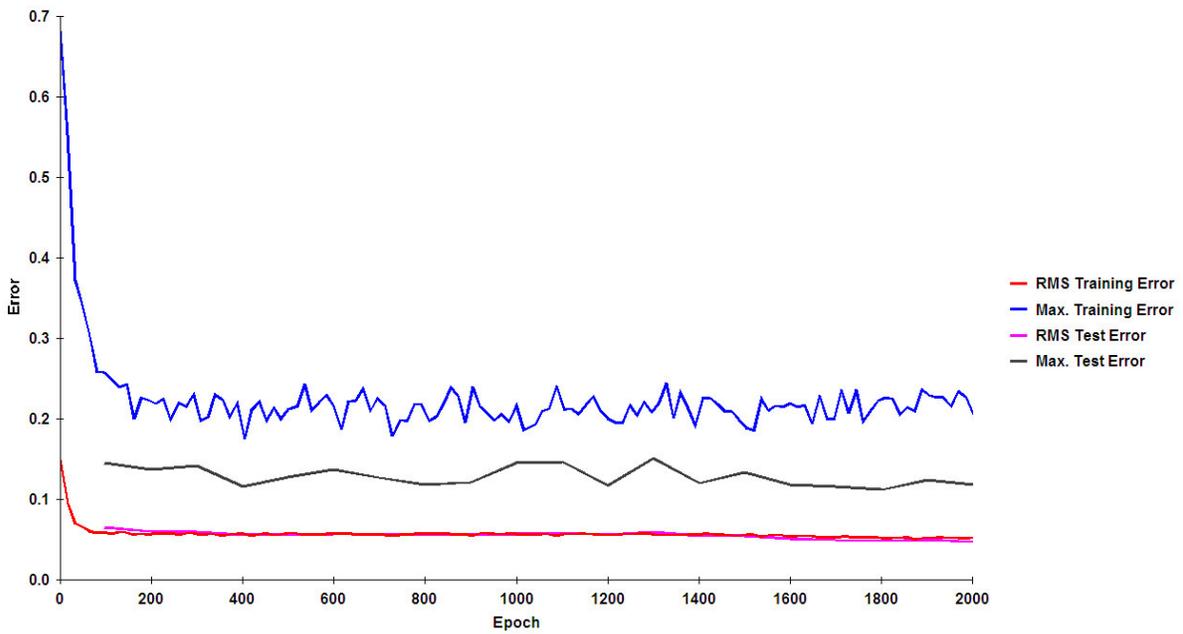
**Left Screenshot (2 HIDDEN AGA\_2.mlp):**

- Architecture:**
  - Input Layer: Number of Neurons = 13, Transfer Function = Linear
  - 1st hidden Layer: Number of Neurons = 2 (highlighted in red), Transfer Function = Sigmoid
  - Output Layer: Number of Neurons = 1, Transfer Function = Linear
  - Number of Connections = 28
- Learning Method:**
  - Learning = Backprop with momentum
  - Learning Strategy = Single Step (Delta)
  - Presentation Order = random
  - Pruning = Off
- Learning Parameters:**
  - 1st hidden Layer: Learning Rate = 0,1, Momentum = 0,55, Weight Decay = 0,999999
  - Output Layer: Learning Rate = 0,01, Momentum = 0,77, Weight Decay = 0,999999
  - Learning Rate Decay = Off
- Weight Initialization:**
  - Lower Bound = -0,1
  - Upper Bound = 0,1
  - Random Seed = 500221
- Stop Conditions:**
  - No. of Epochs is divisible by 2000
  - Perform a Test every 100 Epochs
- Input / Output Files
- State of Training

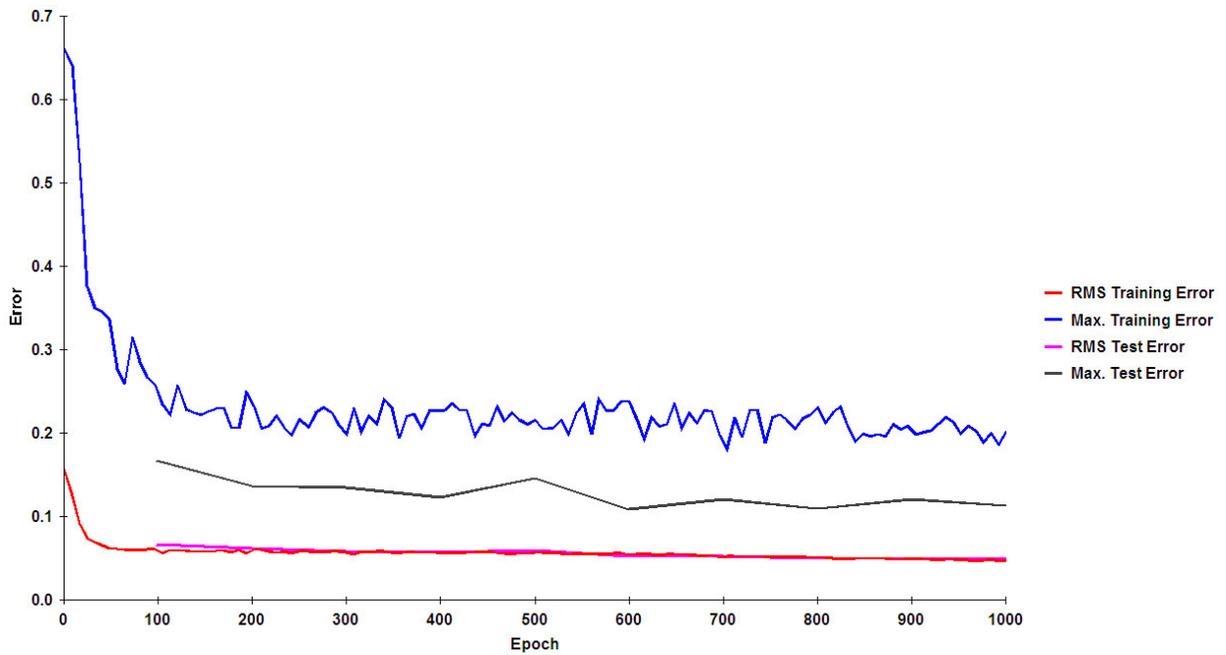
**Right Screenshot (3 HIDDEN AGA\_2.mlp):**

- Architecture:**
  - Input Layer: Number of Neurons = 13, Transfer Function = Linear
  - 1st hidden Layer: Number of Neurons = 3 (highlighted in red), Transfer Function = Sigmoid
  - Output Layer: Number of Neurons = 1, Transfer Function = Linear
  - Number of Connections = 42
- Learning Method:**
  - Learning = Backprop with momentum
  - Learning Strategy = Single Step (Delta)
  - Presentation Order = random
  - Pruning = Off
- Learning Parameters:**
  - 1st hidden Layer: Learning Rate = 0,1, Momentum = 0,55, Weight Decay = 0,999999
  - Output Layer: Learning Rate = 0,01, Momentum = 0,77, Weight Decay = 0,999999
  - Learning Rate Decay = Off
- Weight Initialization:**
  - Lower Bound = -0,1
  - Upper Bound = 0,1
  - Random Seed = 500221
- Stop Conditions:**
  - No. of Epochs is divisible by 1000
  - Perform a Test every 100 Epochs
- Input / Output Files
- State of Training

Epoch:	<input type="text" value="2000"/>	Epoch:	<input type="text" value="1000"/>
max. Training Error:	<input type="text" value="0,207435313053"/>	max. Training Error:	<input type="text" value="0,201736247523"/>
RMS Training Error:	<input type="text" value="0,0528436837606"/>	RMS Training Error:	<input type="text" value="0,0479930812651"/>
max. Test Error:	<input type="text" value="0,118562705773"/>	max. Test Error:	<input type="text" value="0,11342459134"/>
RMS Test Error:	<input type="text" value="0,0472837601656"/>	RMS Test Error:	<input type="text" value="0,0497696689013"/>
<input type="button" value="Update"/>	every <input type="text" value="100"/> steps	<input type="button" value="Update"/>	every <input type="text" value="100"/> steps



**GRÁFICA DEL ENTRENAMIENTO DE LA RED DE 2 NEURONAS EN LA CAPA OCULTA**



**GRÁFICA DEL ENTRENAMIENTO DE LA RED DE 3 NEURONAS EN LA CAPA OCULTA**

**CONEXIONES EN LA RED DE 2 NEURONAS EN LA CAPA OCULTA:**

NO.	DE	A	PESO
1	I0	H1	-3,90542424
2	I0	H2	0,17193793
3	I0	O1	0,304598421
4	I1	H1	-0,45539772
5	I1	H2	-0,17723528
6	I2	H1	0,549506718
7	I2	H2	-0,14191815
8	I3	H1	0,685317917
9	I3	H2	-0,24827912
10	I4	H1	0,816887962
11	I4	H2	0,341292171
12	I5	H1	-0,30473091
13	I5	H2	-0,32871553
14	I6	H1	1,657055889
15	I6	H2	-0,96716331
16	I7	H1	-0,2015493
17	I7	H2	-0,60269533
18	I8	H1	0,210766039
19	I8	H2	-0,96217556

20	I9	H1	0,801235571
21	I9	H2	0,670769286
22	I10	H1	0,546366743
23	I10	H2	-0,06148383
24	I11	H1	0,464433713
25	I11	H2	0,352603607
26	I12	H1	0,141590696
27	I12	H2	0,225640265
28	I13	H1	0,197135621
29	I13	H2	-0,83841095
30	H1	O1	1,348488328
31	H2	O1	-0,66585407

### CONEXIONES EN LA RED DE 3 NEURONAS EN LA CAPA OCULTA:

NO.	DE	A	PESO
1	I0	H1	-0,5115476
2	I0	H2	-3,58743491
3	I0	H3	0,080653875
4	I0	O1	-0,07684357
5	I1	H1	-0,42757774
6	I1	H2	-0,55546092
7	I1	H3	-1,17359554
8	I2	H1	-0,12035427
9	I2	H2	0,383409296
10	I2	H3	-0,59127687
11	I3	H1	-0,1978223
12	I3	H2	0,680657572
13	I3	H3	-0,88599879
14	I4	H1	-0,20743863
15	I4	H2	0,603445978
16	I4	H3	-0,10092802
17	I5	H1	0,123204715
18	I5	H2	-0,18395555
19	I5	H3	0,278871985
20	I6	H1	1,062506788
21	I6	H2	1,712847343
22	I6	H3	0,070878412
23	I7	H1	0,65642434
24	I7	H2	-0,42678702
25	I7	H3	-0,23195517
26	I8	H1	1,063798573
27	I8	H2	0,225420751
28	I8	H3	0,19106457
29	I9	H1	-0,48293049
30	I9	H2	0,847620028

31	I9	H3	0,171993362
32	I10	H1	0,648109752
33	I10	H2	0,262744907
34	I10	H3	0,453489544
35	I11	H1	-1,05801465
36	I11	H2	0,73342295
37	I11	H3	-0,60959545
38	I12	H1	-0,50607285
39	I12	H2	0,345560236
40	I12	H3	-0,03297367
41	I13	H1	0,471365548
42	I13	H2	0,30271226
43	I13	H3	-0,69614235
44	H1	O1	0,655284871
45	H2	O1	1,257883932
46	H3	O1	-0,63163296

La red con 2 neuronas en la capa oculta en la etapa de entrenamiento presentó el error medio de la prueba menor (4.72%) que la red con 3 neuronas en la capa oculta (4.97%), por lo que se considera como más precisa la red con dos neuronas en la capa oculta, presentando a continuación los resultados numéricos de la comparación entre los valores reales y los valores de la prueba de la red.

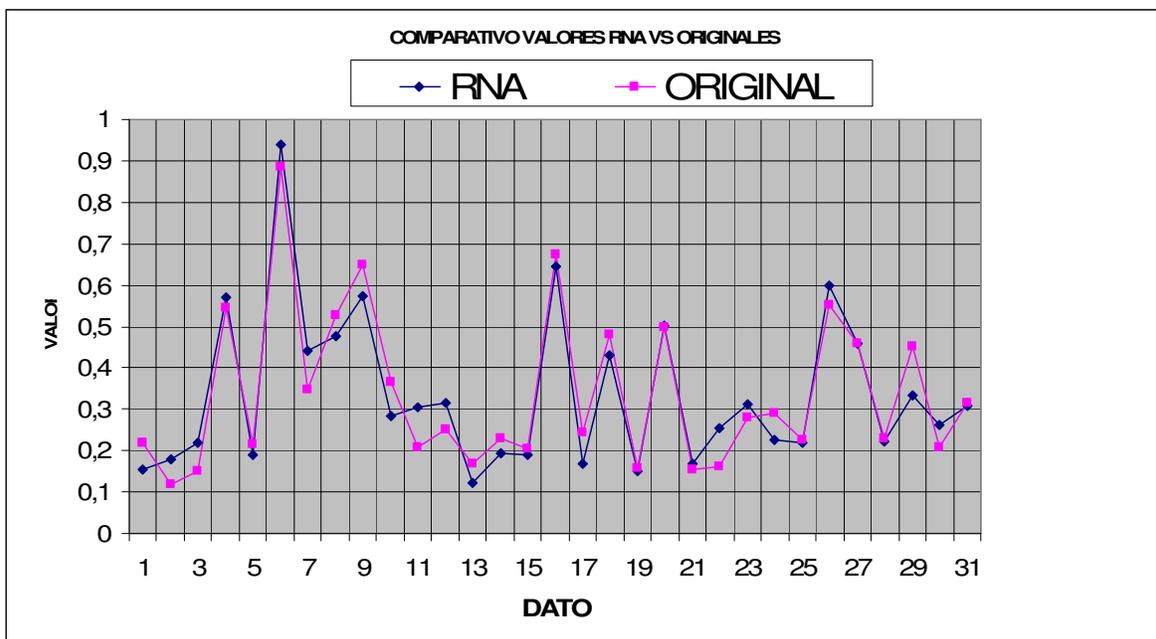
#### PRUEBA:

Una vez realizado el entrenamiento de las redes y determinada la red más eficiente o precisa (la de dos neuronas en la capa oculta) se realizará la prueba, durante la cual se alimentará a la red con la parte de la muestra destinada a test y equivalente en este caso a 31 datos (inmuebles). En esta etapa la red recibirá solo los datos de entrada y deberá calcular los datos de salida: valores los 31 departamentos, los cuales posteriormente se compararán con los datos originales.

#### RESULTADOS DE LA PRUEBA

	RNA	ORIGINAL	VARIACIÓN PORCENTUAL	VARIACIÓN EN PESOS	VALOR ORIGINAL	VALOR CALCULADO POR LA RED
1	0,1549285	0,21835478	-6,343%	-\$58.834,21	\$927.600,00	\$868.765,79
2	0,17754341	0,11794292	5,960%	\$129.094,65	\$2.166.000,00	\$2.295.094,65
3	0,21724664	0,15205744	6,519%	\$111.538,72	\$1.711.000,00	\$1.822.538,72
4	0,56915955	0,54419215	2,497%	\$19.254,86	\$771.200,00	\$790.454,86
5	0,19136749	0,21387178	-2,250%	-\$39.319,49	\$1.747.200,00	\$1.707.880,51
6	0,93990038	0,88551955	5,438%	\$111.698,21	\$2.054.000,00	\$2.165.698,21
7	0,44076008	0,34785144	9,291%	\$124.711,26	\$1.342.300,00	\$1.467.011,26

8	0,4754558	0,52757226	-5,212%	-\$59.318,95	\$1.138.200,00	\$1.078.881,05
9	0,57486586	0,64959726	-7,473%	-\$74.320,38	\$994.500,00	\$920.179,62
10	0,28173229	0,36483581	-8,310%	-\$175.265,32	\$2.109.000,00	\$1.933.734,68
11	0,30445075	0,20618143	9,827%	\$57.566,16	\$585.800,00	\$643.366,16
12	0,31687007	0,25155811	6,531%	\$58.284,39	\$892.400,00	\$950.684,39
13	0,12354815	0,17020811	-4,666%	-\$80.488,43	\$1.725.000,00	\$1.644.511,57
14	0,19414263	0,23103838	-3,690%	-\$30.114,31	\$816.200,00	\$786.085,69
15	0,18989379	0,20450487	-1,461%	-\$15.730,28	\$1.076.600,00	\$1.060.869,72
16	0,64463852	0,6725954	-2,796%	-\$47.504,32	\$1.699.200,00	\$1.651.695,68
17	0,16887568	0,24240988	-7,353%	-\$116.853,20	\$1.589.100,00	\$1.472.246,80
18	0,43154881	0,4812115	-4,966%	-\$54.986,53	\$1.107.200,00	\$1.052.213,47
19	0,15097751	0,1589095	-0,793%	-\$24.354,40	\$3.070.400,00	\$3.046.045,60
20	0,50046304	0,49979954	0,066%	\$888,29	\$1.338.800,00	\$1.339.688,29
21	0,16942526	0,1544994	1,493%	\$25.344,12	\$1.698.000,00	\$1.723.344,12
22	0,25554267	0,16193461	9,361%	\$70.262,21	\$750.600,00	\$820.862,21
23	0,31309298	0,27947662	3,362%	\$19.168,05	\$570.200,00	\$589.368,05
24	0,22580311	0,29124904	-6,545%	-\$40.340,87	\$616.400,00	\$576.059,13
25	0,21989228	0,22724788	-0,736%	-\$6.497,20	\$883.300,00	\$876.802,80
26	0,59682058	0,5505704	4,625%	\$53.021,21	\$1.146.400,00	\$1.199.421,21
27	0,45878117	0,4589423	-0,016%	-\$98,40	\$610.700,00	\$610.601,60
28	0,22073446	0,22987207	-0,914%	-\$10.770,50	\$1.178.700,00	\$1.167.929,50
29	0,33174163	0,45030433	-11,856%	-\$111.282,96	\$938.600,00	\$827.317,04
30	0,26152014	0,2085505	5,297%	\$56.402,08	\$1.064.800,00	\$1.121.202,08
31	0,30705988	0,31639757	-0,934%	-\$11.156,67	\$1.194.800,00	\$1.183.643,33



## CONCLUSIONES.

1. En el caso práctico realizado resultó más conveniente la red perceptrón multicapa con 2 neuronas en la capa oculta, cuyo error medio de la prueba equivale a 4.72% y el error máximo es de solo 11.85% contra el 4.97% medio y 11.34% el máximo en el caso de la red con 3 neuronas en la capa oculta.
2. La red perceptrón multicapa es una herramienta adecuada para hacer análisis de datos de los inmuebles que nos permite predecir adecuadamente el valor del inmueble con un error medio muy bajo.
3. La red es capaz de hacer análisis de las variables no solo cuantitativas sino también cualitativas, sin la necesidad de la intervención subjetiva de los “expertos” ni la utilización de calificativos empíricos del tipo casi igual, mejor, mucho mejor, francamente mejor, un poco peor, peor, mucho peor, francamente peor, etc., los cuales en el caso de sistema multicriterio AHP se traducen en una rígida escala numérica, dónde a cada gradiente se asigna un valor a priori en base al método de comparación pareada; mientras que en el caso de la red tipo perceptrón multicapa los pesos de cada una de las variables cambian constantemente hasta ajustarse para producir el menor error posible.
4. El experimento demostró que en el proceso de valuación de un inmueble juegan un papel importante todas las variables (en el caso del experimento se utilizaron 15).
5. La red busca relaciones entre todas las variables tanto cualitativas como cuantitativas al mismo tiempo utilizando funciones no lineales, mostrándose superior a la regresión lineal, que solo es capaz de hacer representaciones lineales.
6. La red no trabaja con base en modelos matemáticos rígidos como lo hace la regresión, es decir la red no se programa obligándola a seguir una sentencia predefinida de instrucciones. La red trabaja en base al aprendizaje. Siendo un sistema adoptivo, genera ella misma sus propias “reglas” y aprende de sus propios errores para poder llegar a la solución óptima del problema.
7. Para poder trabajar correctamente la red requiere de algún tipo de patrón. Y es por eso que no pueden predecir la lotería o la carrera de caballos, que son procesos al azar.

8. Tiene alta plasticidad y adaptabilidad que se debe a su capacidad de aprendizaje y por lo tanto es capaz de cambiar dinámicamente junto con el medio gracias al constante cambio de los pesos en las conexiones entre sus neuronas, para responder correctamente a los estímulos de entrada.
9. La red neuronal tipo perceptrón multicapa es una herramienta de gran utilidad en la valuación inmobiliaria, pudiendo ser implementada como instrumento de auditoría de avalúos en las unidades de valuación. Gracias a su funcionamiento sencillo, rápido y preciso puede ser una aliada de los sistemas de gestión de calidad en los despachos, dónde diariamente se genera una gran cantidad de avalúos realizados por valuadores cuyo trabajo no siempre puede ser supervisado cabalmente por un controlador, dónde error humano, tanto del valuator como del controlador es siempre presente, sobre todo cuando hay una considerable carga de trabajo.
10. Asimismo la red neuronal podría tener una gran aplicación dentro de la Sociedad Hipotecaria Federal, como una herramienta de auditoría de todas las Unidades de Valuación, garantizando así el servicio de calidad de esta institución y poder detectar con rapidez y precisión todas las posibles anomalías y errores en los miles de avalúos que se generan diariamente en todas las Unidades de Valuación.
11. Otra de las aplicaciones de la red neuronal tipo perceptrón multicapa podría ser la determinación de los valores catastrales, pudiendo esta rápida herramienta hacer ahorrar tiempo y dinero a las tesorerías y garantizar la actualización constante de los valores de los inmuebles.
12. Se considera que una de las desventajas de esta herramienta es su naturaleza de “caja negra”, es decir que no se puede conocer la descripción del modelo matemático que explica el comportamiento de una serie de datos y solo se podrá obtener los resultados (valores calculados o predichos). Esta afirmación es correcta solo parcialmente. Si es posible conocer la expresión matemática por medio de la cual la red calcula el valor de salida (el valor del inmueble), solamente que se trata de ecuaciones del grado  $n$ , que van más allá de los conocimientos de matemáticas de la mayoría de los valuadores.
13. El reducido número de comparables para la determinación del valor de un inmueble (el avalúo para crédito garantizado a la vivienda debe contener 6 comparables, mientras que el formato de la Tesorería del DF solamente 4). fácilmente puede prestarse a la manipulación de datos y de consecuencia del valor por parte del valuator, en el sentido de que dentro de los 6 o 4 comparables pueden encontrarse o los inmuebles más caros o los más

baratos según la conveniencia, mientras que la introducción de mayor número de comparables alargaría todavía más el ya largo tiempo que requiere la realización de un avalúo. Por otro lado la RNA puede calcular el valor del inmueble con base en un número infinitamente superior de comparables (cientos o miles dependiendo de la base de datos a disposición) en cuestión de segundos y con mayor precisión, eliminando totalmente la subjetividad del valuador.

14. El modelo no tiene características explicativas y por lo tanto no es auditable en los términos de formato tradicional de un avalúo, sin embargo creo que es necesario que el gremio de los valuadores se abra a las nuevas formas de valuación aceptando que el futuro de la valuación está no en un valuador solitario y una hoja de cálculo Excel, sino en el trabajo de equipo multidisciplinario, aplicando los últimos avances tecnológicos en pro de la calidad, eficiencia, precisión y rapidez del trabajo.

## BIBLIOGRAFÍA

Caridad y Ocerín J.M., Cuellar Villamados N., *Un análisis de mercado de vivienda a través de redes neuronales artificiales*, Publicación: *Estudios de Economía Aplicada* nº 18, 2001, pag. 67-81.

Ing. Piol Puppio Roberto, *Redes Neuronales aplicadas al Avalúo Inmobiliario*, Sociedad de Ingeniería de Tasación de Venezuela (SOITAVE), (en [www.monografias.com](http://www.monografias.com))

Mora Esparza Julio Gallego, Gerencia Regional del Catastro de Madrid, *La inteligencia artificial aplicada a la valoración de inmuebles. Un ejemplo para valorar Madrid*, abril 2004

Do and Grudnitski, *Predicting Housing Value: A comparison of multiple regression analysis and artificial neural networks*, *The Journal of Real Estate Research*, nov/dec 2001

Lara Cabeza J.M., *Aplicación de las redes neuronales artificiales al campo de la valoración inmobiliaria*, [www.mappinginteractivo.com](http://www.mappinginteractivo.com) revista internacional de Ciencia de la Tierra, Septiembre 2005;

Un análisis del mercado de la vivienda a través de sistemas de redes neuronales (2000) *Revista Española de Economía Aplicada* 1 7-13

*Redes neuronales y modelos hedónicos en problemas de valoración urbana* (2001) *Revista Estudios Empresariales Edición Especial de Economía Urbana* 8 111-129

Modelos de valoración urbana (1998) XII Reunión de ASEPELT

Anderson James A., *Redes Neuronales*, Alfaomega Grupo Editor, México, agosto 2007, pp. 612.