

La inteligencia artificial aplicada a la valoración de inmuebles. Un ejemplo para valorar Madrid

Julio Gallego Mora-Esperanza
Gerencia Regional de Madrid

La Inteligencia Artificial y los sistemas tradicionales

Es conocido que la informatización de la valoración de inmuebles comenzó a principios de los años 80, coincidiendo con el desarrollo de los sistemas informáticos. Posteriormente se fueron incorporando diversas técnicas estadísticas para el tratamiento de la información de mercado, entre las que tuvo especial relevancia la Regresión Múltiple.

La utilización de Sistemas de Inteligencia Artificial en la valoración de inmuebles es más reciente pues comenzó hace unos 15 años. En este tiempo ha habido numerosas experiencias, y la creación de nuevos modelos va en aumento. Entre los autores que han desarrollado los sistemas más interesantes (algunos de cuyos escritos han servido de base para la elaboración de este informe), cabe citar los que se recogen en el cuadro 1.

No es práctico pensar que este tipo de trabajos constituye una actividad experimental y lejana. En la última década la Inte-

ligencia Artificial ha tenido un desarrollo muy fuerte y ya funciona en España en determinados campos. Así por ejemplo, la Agencia Tributaria ha preparado recientemente un sistema de Inteligencia Artificial para la detección del fraude fiscal en el I.V.A.

En el campo de la valoración inmobiliaria ha habido numerosos estudios que han comparado los sistemas de Inteligencia Artificial con los métodos tradicionales de

Cuadro 1
Utilización de Sistemas de Inteligencia Artificial

Autor	Año	Área de estudio
Borst	1991	Nueva Inglaterra
Tay y Ho	1992	Singapur
Do y Grudnitiski	1992	California
Evans	1993	Reino Unido
Worzala	1995	Colorado (U.S.A.)
Borst	1995	Nueva Inglaterra
Mc Cluskey	1996	
Rossini	1997	Sur de Australia
Haynes y Tan	1998	Gold Coast en Australia
Bonissone	1998	
Cechin	2000	Porto Alegre (Brasil)

valoración, y en particular con la Regresión Múltiple. La mayoría de estos estudios calculan el porcentaje de error de un sistema de Inteligencia Artificial y de otro de Regresión Múltiple, haciéndolos funcionar con un conjunto de muestras de mercado de las que se conoce su precio de venta.

Los resultados de estas comparaciones parecen claros. Los Sistemas de Inteligencia Artificial muestran en las pruebas unos errores medios que se sitúan entre el 5 y el 10%, mientras que los de Regresión Múltiple se sitúan más entre el 10 y el 15%. De todas formas, en alguna de estas pruebas los resultados han sido similares para ambos sistemas pero, en general, los estudios realizados muestran una mayor precisión de los Sistemas de Inteligencia Artificial.

Otra de las ventajas que, según los estudios, tienen los Sistemas de Inteligencia Artificial respecto a la Regresión Múltiple, es su capacidad para estimar el valor de las propiedades que presentan características significativamente diferentes de las de los bienes de su entorno (outliers). Esto es así debido a que los Sistemas de Inteligencia Artificial someten a las muestras a un proceso matemático mucho más complejo que el de la Regresión Múltiple, la cual se limita a construir una simple ecuación polinómica. De todas formas, esta ventaja no se pone de manifiesto en todos los estudios, y en algunos de ellos se indica que también los Sistemas de Inteligencia Artificial tienen algunos problemas para estimar con precisión los valores de las propiedades especiales (outliers).

El cerebro y los ordenadores

La Inteligencia Artificial ha progresado con el estudio del funcionamiento del cerebro humano.

Hasta hace poco los procedimientos de estudio del cerebro permitían visualizar su interior y detectar daños físicos, pero no suministraban información sobre su fun-

cionamiento. Hoy en día las modernas técnicas de Tomografía permiten analizar algunos procesos cerebrales. El conocimiento del cerebro avanza con rapidez, y está permitiendo realizar comparaciones muy interesantes entre su funcionamiento y el de los ordenadores.

No era extraño pensar, hasta hace poco, que los ordenadores y el cerebro guardaban una cierta analogía en cuanto a su estructura y su funcionamiento. En efecto, ambos son capaces de captar información del exterior, y ambos pueden guardar datos en su memoria para utilizarlos en el futuro, y con los datos externos y los de la memoria pueden realizar procesos internos para obtener resultados.

Sin embargo, los avances en el conocimiento del cerebro han permitido descubrir que su estructura y su funcionamiento son completamente distintos a los de los ordenadores.

Este descubrimiento no ha sido reciente ni repentino, pues desde el funcionamiento de los primeros ordenadores ya se advertían algunas diferencias relevantes.

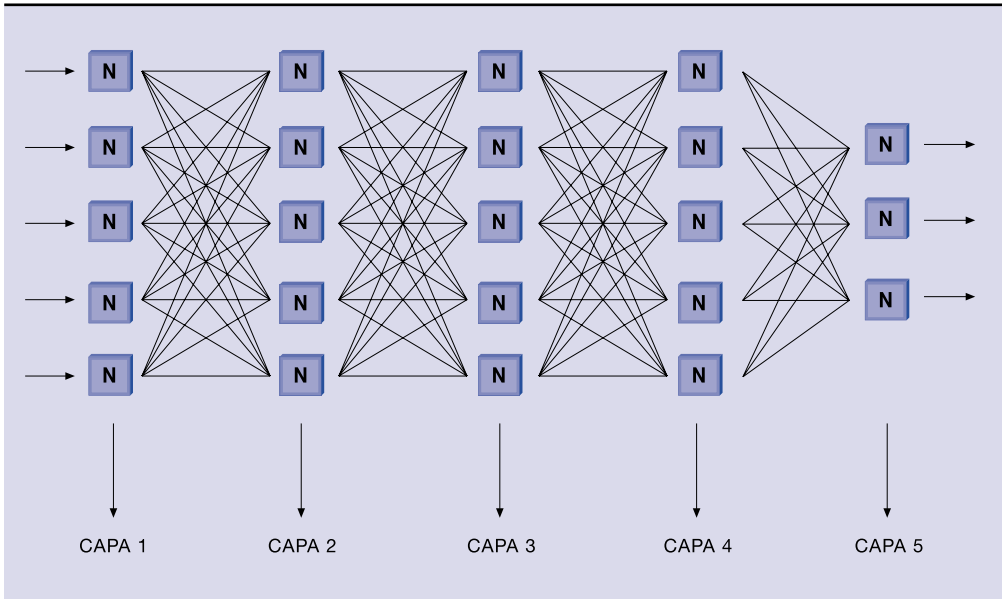
En primer lugar, es evidente que los ordenadores tienen una capacidad y precisión para el cálculo, y una velocidad de proceso de datos muy superiores a las del cerebro. Se estima que la transmisión de datos en el cerebro es del orden de un millón de veces más lenta que en el interior de un ordenador. Los cálculos que realiza un ordenador de pequeño tamaño son inasumibles para una persona.

Según esto se podría decir que el cerebro es un “ordenador malo”, pero lo que sucede en realidad es que el cerebro tiene poco que ver con los ordenadores.

A medida que la capacidad de los ordenadores iba aumentando, se les iban asignando nuevas tareas, pensando que serían capaces de hacer de todo. Sin embargo se ha comprobado que hay determinadas tareas que los ordenadores no resuelven bien.

Una de estas tareas es la del “Reconocimiento de Imágenes”, por ejemplo para la

Gráfico 1
Red de capas en el cerebro humano



clasificación de variedades de fruta, o para el reconocimiento de caras de personas en el control de acceso a un edificio. Sin embargo, a pesar de las muchas líneas de programación que se iban añadiendo el resultado no era bueno.


¿Cómo puede ser que un ordenador, con su velocidad de proceso y su capacidad de cómputo, tenga serios problemas para reconocer una cara, cuando una persona puede hacerlo en un instante?

Tampoco han tenido éxito los ordenadores en imitar la forma de caminar de las personas. Se ha considerado de interés que algunos ingenios de robótica dispongan de patas, en lugar de ruedas, para acceder a lugares peligrosos y escarpados (por ejemplo zonas volcánicas). Los resultados han sido bastante frustrantes, y no solo por la complejidad que tiene imitar la estructura de las piernas, sino porque el ordenador que tiene que controlar el movimiento tiene muchas dificultades para procesar la enor-

me cantidad de datos que van cambiando a cada paso para mantener el equilibrio. Sin embargo, una persona aprende a caminar con cierta rapidez en su infancia, en cuanto tiene fuerza en las piernas para sostenerse.

La respuesta a estas cuestiones consiste en que el ordenador y el cerebro tienen una estructura y un funcionamiento muy diferente. El ordenador contiene una estructura de microprocesadores conectados principalmente "en serie", lo que le permite alcanzar velocidades muy altas en la transmisión de los datos. El cerebro también tiene algo similar a los microprocesadores, son las neuronas, pero están organizadas de otra manera.

Las neuronas no están conectadas entre sí "en serie". Cada neurona está conectada con varias neuronas, de modo que recibe información de algunas de ellas a través de unas conexiones denominadas "Dentritas", y después de realizar su proceso interno, envía su información a otras neuronas mediante conectores denominados "Axon"



La diferencia fundamental consiste, por tanto, en que las neuronas están conectadas entre sí “en paralelo” y de forma masiva, formando capas.

Esta estructura implica que cada neurona puede estar conectada con muchas otras. La información de entrada se distribuye entre una gran cantidad de neuronas que trabajan en paralelo. En cada momento hay muchas neuronas procesando la información simultáneamente.

Esto hace, como ya hemos visto, que el proceso sea más lento, pero de esta forma el cerebro puede trabajar con la gran cantidad de información que precisan las tareas ya mencionadas, y puede manejar información parcialmente errónea, redundante e incompleta sin que esto afecte excesivamente a los resultados.

Además, un ordenador tiene un número de procesadores muy limitado, en comparación con un cerebro. Es difícil que un ordenador pueda tener un millón de microprocesadores, mientras que el cerebro de un insecto puede alcanzar esta cifra de neuronas. Es verdad que los insectos no tienen capacidad de cálculo matemático, pero realizan funciones complejas necesarias para su supervivencia.

El cerebro humano tiene entre 10.000 millones y 100.000 millones de neuronas, conectadas en una compleja red de capas.

Esta estructura del cerebro está orientada al aprendizaje, y esto constituye una diferencia fundamental con los ordenadores. Para muchas tareas el cerebro no está programado sino que “aprende”.

La programación de un ordenador, por muy compleja que sea, es fija. Por el contrario, el cerebro cambia su proceso interno

al comprobar los errores que va cometiendo, para reducir el error al mínimo.

El ordenador está “programado”, mientras que el cerebro “aprende”, y este aprendizaje lo lleva a cabo probando.

Supongamos que las neuronas se transmiten impulsos unas a otras para que el cuerpo se levante y comience a andar. Si en el primer intento el cuerpo se cae hacia la derecha, ese error es recogido por el cerebro, que alterará la cuantía de los impulsos de las neuronas para corregirlo. En el siguiente intento el proceso entre las neuronas será algo diferente, debido a esta corrección, y si el cuerpo se inclina ahora hacia delante, se volverá a ajustar el sistema con este error, y así sucesivamente, hasta conseguir mantener el equilibrio.

De esta forma es como se aprende a andar, a mantener el equilibrio, a montar en bicicleta, etc. El cerebro ajusta continuamente sus procesos mediante el sistema de prueba y error.

La gran capacidad de proceso del cerebro, y su sistema de aprendizaje, le hacen ser muy “adaptable” a la cambiante situación externa, y es capaz de abordar una enorme variedad de tareas. Esta capacidad de “adaptación” le permite realizar las tareas propias de un ingeniero industrial, o de un tenista profesional o de un músico.

En conclusión, los ordenadores tradicionales fueron diseñados para disponer de una gran capacidad de cómputo, pero no para que funcionasen de forma análoga a la mente humana.

La Inteligencia Artificial y la Redes Neuronales Artificiales (RNA)

Una vez que se conocieron estos principios básicos de la estructura y funcionamiento del cerebro, era evidente que había que construir sistemas informáticos que los imitasen, y así poder abordar con posibilidades de éxito las tareas que los ordenadores tradicionales no resolvían bien.

De esto se ocupó la Inteligencia Artificial.

La Inteligencia Artificial tiene varias modalidades. Una de las más importantes la constituyen las Redes Neuronales Artificiales (RNA).

Las RNA consisten en sistemas informáticos en los que los microprocesadores, en lugar de disponerse “en serie” como en los ordenadores tradicionales, se conectan “en paralelo”, formando capas y con múltiples conexiones, tal y como se organiza la red de neuronas en el cerebro.

Por supuesto que no se trata de simular un cerebro humano, sino solo de construir un sistema que funcione de forma análoga y en pequeña escala. De hecho hay RNA que se construyen con poco más de 20 “neuronas” (microprocesadores).

Inicialmente las “neuronas artificiales” eran microprocesadores, pero en la actualidad estos han sido sustituidos en la mayoría de los casos por programas informáticos que imitan su funcionamiento.

Actualmente las RNA están muy desarrolladas, y se aplican en multitud de campos: diagnóstico de enfermedades, análisis de riesgos en la concesión de créditos, predicción de la evolución de los mercados de valores, etc.

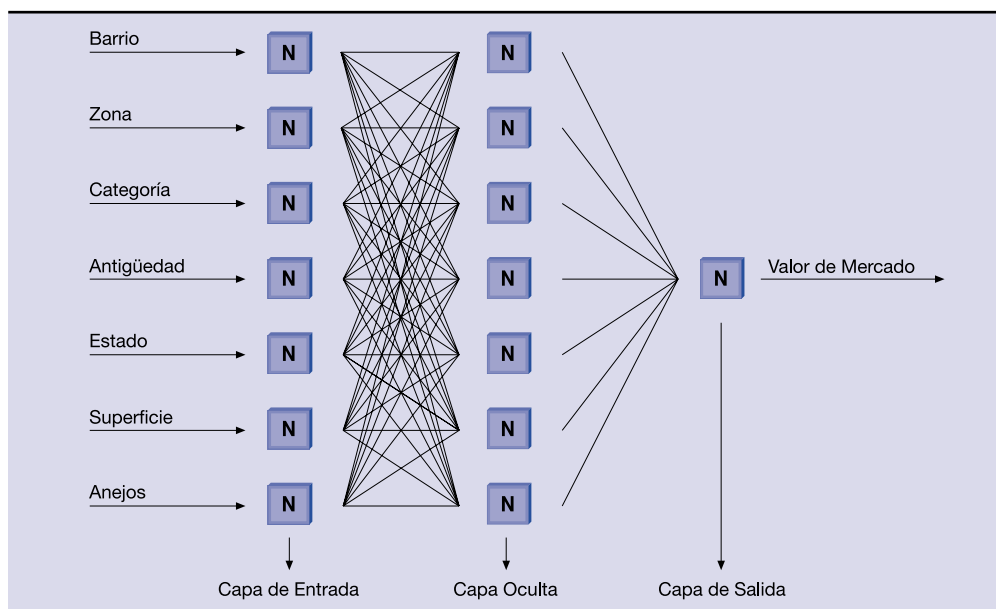
El sistema de Inteligencia Artificial desarrollado por la Agencia Tributaria para la detección del fraude en el I.V.A. es una RNA.

La mayoría de los sistemas de Inteligencia Artificial desarrollados para la valoración de inmuebles son RNA.

Las Redes Neuronales Artificiales y la valoración de inmuebles

Para entender el funcionamiento de una RNA vamos a ver un ejemplo típico de aplicación a la valoración de inmuebles.

Gráfico 2
Red Neuronal Artificial para la valoración de inmuebles



Este ejemplo recogido en el gráfico 2, cuenta con 15 neuronas organizadas en 3 capas. La capa primera recibe los datos de entrada, y tiene 7 neuronas. La capa segunda se denomina capa oculta, y también tiene 7 neuronas. La tercera capa es la capa de salida, que tiene una única neurona, y en ella se genera el resultado final: el Valor de Mercado.

Las RNA para la valoración de inmuebles suelen trabajar con un número de variables que suele oscilar entre las 10 y las 50, por lo que tienen una capa de entrada con este número de neuronas, y una capa oculta que suele tener el mismo número de neuronas (si bien a veces oscila entre la mitad y el doble), así como una capa de salida de una neurona.

Existen múltiples formas de diseñar una RNA. Se pueden incluir más o menos capas, y más o menos neuronas por capa. Cada neurona puede enviar sus datos a las neuronas de la capa siguiente (conexión hacia adelante), o a las de su propia capa (conexión lateral), o a las de la capa anterior (conexión hacia atrás). Una neurona puede recibir información de todas las neuronas de la capa anterior (conexión total), o solo de parte (conexión parcial).

Hay numerosas recomendaciones de diseño para organizar la estructura de una RNA. Se refieren al número de capas, número de neuronas por capa, conexiones, etc. Pero en realidad no existen reglas fijas, y los diseños se ajustan probándolos.

La mayoría de las RNA diseñadas para la valoración de inmuebles tienen una estructura similar a la indicada, es decir que son sistemas de “Conexión Total Hacia Adelante”.

Prueba y error

Las RNA no funcionan a la primera. Es necesario “entrenarlas”, es decir, que tienen que “aprender”. Para ello se las somete a unos ciclos de Prueba y Error.

Para comprender este proceso vamos a ver como funciona una neurona artificial,

cuyo funcionamiento intenta imitar al de las neuronas del cerebro.

La neurona recibe datos de otras neuronas. En las RNA estos datos son números. Cada neurona recibe, por tanto, un número de cada neurona que le envía información (x_1, x_2, x_3 , etc.), y envía a las siguientes neuronas otro número (a todas el mismo número) que es el resultado de su proceso (R).

Como se ve en el esquema que recoge el gráfico 3, los datos numéricos enviados por otras neuronas (x_1, x_2, x_3 , etc.), no se procesan tal cual llegan, sino que a cada variable de entrada se le asigna un peso (a_1, a_2, a_3 , etc.). Estos pesos son muy importantes porque en ellos radica la capacidad de aprendizaje de la neurona y del sistema.

Una vez asignados los pesos, la neurona realiza internamente dos operaciones. Primero calcula el número “S”, como resultado del sumatorio de cada variable por su peso. En segundo lugar, calcula el número “R” aplicando al número anterior una función de transferencia, $R=f(S)$ (la función más utilizada para las neuronas de las RNA es la función sigmoidea, por su sencillez para ser manejada en la programación informática: $R=1/(1+e^{-S})$). Por último, el número “R” así obtenido se envía a las neuronas siguientes (salvo que se trate de la neurona de la capa final, en cuyo caso “R” sería el resultado, es decir, el valor de mercado).

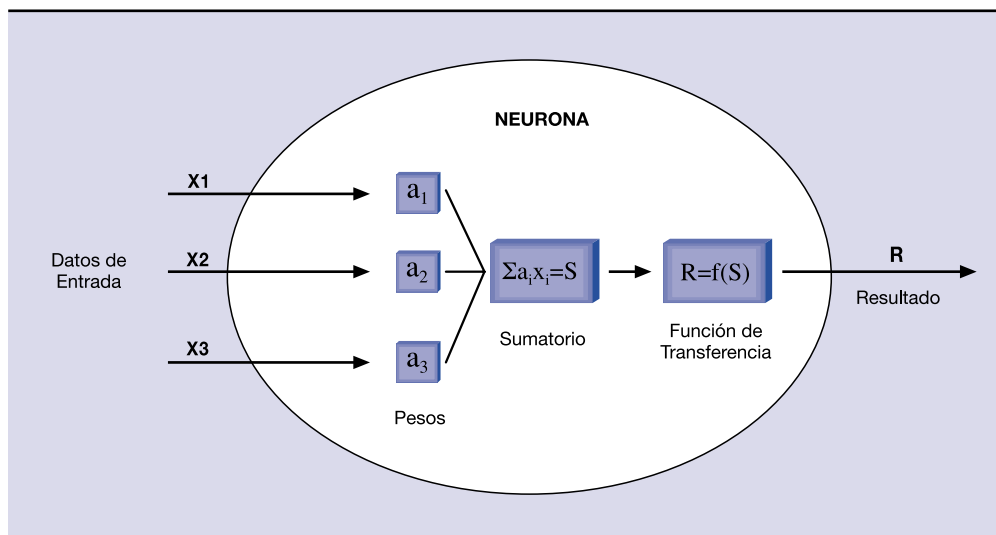
Una vez analizado el funcionamiento de una neurona, vamos a ver como opera en el sistema al completo.

La RNA tiene dos modalidades de trabajo, una de “entrenamiento o aprendizaje” y otra de “producción”.

En la fase de entrenamiento se seleccionan un conjunto de muestras de las que se conocen todas las variables y también el valor de mercado.

No hay cifras establecidas para determinar el número de muestras que son necesarias para entrenar correctamente una RNA, pero hay algunas recomendaciones que

Gráfico 3
Esquema de funcionamiento de una neurona artificial



indican que su número debe ser proporcional al número de variables de entrada.

Supongamos que para nuestro ejemplo, de 7 variables, disponemos de 60 muestras de entrenamiento.

En primer lugar, se dividen las muestras en dos grupos: uno para “entrenar” el sistema y otro para “comprobarlo”. Así, siguiendo el ejemplo, las 60 muestras las dividimos en un grupo de 40 para entrenamiento y otro grupo de 20 para comprobación. Más adelante veremos la utilidad de estas muestras de comprobación.

Seguidamente comenzamos a entrenar el sistema, para lo cual le aportamos los datos de la primera muestra. Para que el sistema pueda funcionar tenemos que asignarle antes los “pesos” (a_1 , a_2 , a_3 , etc.) de cada neurona. Esto se hace inicialmente asignando unos valores aleatorios.

El sistema calcula entonces el valor de mercado de la primera muestra “R”.

Una vez que se ha obtenido este primer resultado, el sistema lo compara con el valor de mercado real de la muestra, que es cono-

cido, y obtiene el “error” o diferencia entre el valor calculado y el real. Lógicamente, en esta primera pasada el error será alto.

Después de calcular este primer error, un algoritmo de corrección modifica los pesos de todas las neuronas de la Red, con el objetivo de reducir el error al mínimo.

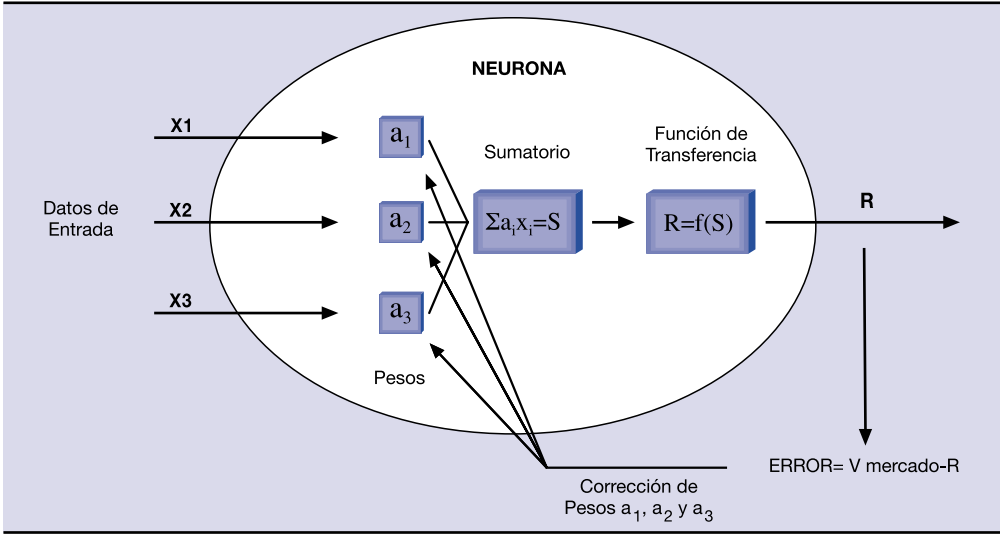
En el gráfico 4 se ve el funcionamiento de la corrección para una neurona, pero el sistema lo hace para todas las neuronas.

Al diseñar la Red, se puede programar el algoritmo de corrección que se quiera, pero habitualmente se emplea uno estándar que se llama “algoritmo de corrección hacia atrás” (y que es una generalización de la regla Delta).

Una vez que se han corregido los pesos de las neuronas (a_1 , a_2 , a_3 , etc.), se vuelve a procesar una muestra y se vuelve a obtener un nuevo resultado, que se compara de nuevo con el valor de mercado conocido para obtener el nuevo error.

El algoritmo vuelve a corregir los pesos, y se va repitiendo iterativamente este proceso con todas las muestras de

Gráfico 4
Esquema de funcionamiento de una neurona. Fase de corrección



prueba hasta reducir el error al mínimo (no a cero).

El ordenador puede repetir este proceso de ajuste cientos de veces, incluso miles de veces, en pocos segundos, hasta conseguir una gran aproximación al valor de mercado.

De esta forma el sistema se ajusta “probando”, de una forma análoga a como lo hace el cerebro.

Entrenamiento y comprobación

¿Cómo podemos saber cuándo una RNA está ya bien entrenada?

¿Cuántas veces hay que pasar el ciclo de corrección?

¿Cien, mil, o diez mil veces?

Por lo general estas cuestiones se resuelven haciendo pruebas. De todas formas, los entrenadores de la Red manejan algunos conceptos básicos para ajustarla, como son el “ratio de aprendizaje”, el “momento”, el “ruido de entrada”, y

las “tolerancias de entrenamiento y prueba”.

Pero no es necesario entrar en estos conceptos para entender como debe realizarse el entrenamiento. En primer lugar es evidente que cuantas más variables de entrada haya, será necesario disponer de más muestras de prueba, y al haber más muestras habrá que pasar más ciclos de ajuste.

A primera vista podría parecer que cuantas más veces se repita el ciclo de corrección será mejor, pues reduciremos cada vez más el error, y nos iremos aproximando cada vez más al valor de mercado exacto de las muestras de prueba.

Pues bien, la práctica demuestra que esto no es así. A partir de un determinado número de ciclos de corrección del error la Red comienza a estar “sobre-entrenada”, esto es, que se está adaptando demasiado a las 40 muestras de entrenamiento, pero comienza a empeorar sus resultados respecto a otras muestras.

Para verificar esto es por lo que en el epígrafe anterior comentábamos que con las 60

muestras iniciales, de las que se conocía el valor de mercado, se hacían dos grupos, uno de 40 muestras para el entrenamiento, y otro de 20 muestras para la comprobación.

La Red se entrena con el grupo de 40 muestras, pero con las 20 muestras de comprobación iremos verificando que no nos hemos quedado cortos, ni nos hemos pasado en el número de ciclos de corrección del error.

De esta forma se determina el número de ciclos de corrección del error necesarios para entrenar la Red.

Una vez que, con las 20 muestras de comprobación, hemos verificado que la Red se sitúa en un nivel de error admisible (normalmente inferior al 5%), se termina la fase de “entrenamiento”, y comienza la fase de “producción”, en la que utilizaremos la RNA para estimar el valor de mercado de inmuebles en los que este dato es desconocido.

Las RNA pueden volver a la fase de “entrenamiento” cuando se quiera. De hecho, conviene entrenarlas cada cierto tiempo, ya que el mercado va cambiando.

Ventajas e inconvenientes

Ya se han apuntado algunas de las ventajas que presentan las RNA respecto a los sistemas anteriores: una mayor precisión, y una mayor capacidad para estimar el valor de las propiedades especiales (outliers).

También hay que apuntar que el manejo para el usuario es muy sencillo. Solo tiene que introducir las variables conocidas por un lado y obtener el valor de mercado por el otro. Lo que sucede en el interior no tiene por qué preocuparle. El diseño y el entrenamiento de la Red deben ser realizados por personas que entiendan de esta materia, pero el uso de la Red en la modalidad de “producción” es muy sencillo.

Además, si bien a primera vista puede parecer que la tecnología de las RNA es algo compleja, en realidad se utilizan muy

pocas fórmulas, las cuales suelen ajustarse a unos estándares establecidos. Una RNA puede instalarse perfectamente en un micro-ordenador, incluso sobre un software de hoja de cálculo.

En cuanto a los inconvenientes, conviene apuntar uno de cierta importancia.

A las RNA se las llama también “cajas negras”, ya que es imposible saber qué es lo que pasa en su interior. No hay manera de explicar cómo una RNA calcula el valor de mercado de los inmuebles, ni con ecuaciones ni con tablas ni con nada. La complejidad del proceso iterativo de corrección de pesos, de sumatorios y de funciones de transferencia dentro de las múltiples conexiones de neuronas hace imposible esta tarea.

Esto puede no ser un problema para las empresas privadas, y de hecho no lo está siendo, pues las RNA se están extendiendo y perfeccionando con rapidez en este sector en múltiples aplicaciones.

Pero cuando se trata de calcular valores de inmuebles con fines tributarios, la Administración debe explicar de alguna manera a los contribuyentes y a los Tribunales Económicos cómo lo ha hecho.

Es cierto que los contribuyentes y los Tribunales tampoco entendían la Regresión Múltiple, pero formalmente estos sistemas disponen de una explicación válida, aunque sea difícil. El problema es que las RNA no disponen de ninguna explicación, ni fácil ni difícil.

Por ello algunos expertos están desarrollando métodos que permitan describir de forma sencilla el funcionamiento de una RNA.

De todas formas, este inconveniente no tiene por qué ser un verdadero problema para que la Administración utilice las RNA en la valoración de inmuebles. Hay que tener en cuenta que el peso de la explicación de los resultados no tiene por qué recaer enteramente en la Red. Estos sistemas deben ser “herramientas” de ayuda al valorador en su trabajo, y no sistemas cerrados

que sustituyan al valorador. De hecho, ya hay varios países que han incluido RNA en sus sistemas informáticos de valoración de inmuebles, como herramientas de ayuda a sus valoradores.

Un ejemplo para valorar Madrid

Para verificar las cualidades de este sistema, se ha preparado una RNA destinada a valorar la vivienda colectiva en la Región de Madrid. Se ha elegido este uso por ser el predominante en Madrid, ya que incluye unos dos millones de viviendas, y supone cerca de dos tercios del total de las propiedades de la Región.

En lugar de trabajar con las viviendas colectivas de un municipio concreto, se ha preferido abordar todo el territorio regional, ya que un ámbito de este tipo supone una mayor complejidad y permite poner a prueba la capacidad de la RNA. Además, si la RNA fuese capaz de definir un modelo regional, esto podría permitir llevar a cabo un seguimiento continuo del mercado inmobiliario de forma bastante eficaz.

La Red se ha elaborado sobre una Hoja Electrónica, y contiene los elementos básicos de las RNA. El sistema permite añadir o reducir el número de capas y el número de neuronas por capa, así como incorporar las funciones de transferencia y los algoritmos de corrección que se consideren más adecuados. De todas formas, los cambios hay que realizarlos grabando las fórmulas en la Hoja de Cálculo, ya que no se ha pretendido desarrollar un sistema informático estándar de RNA, sino solamente una aplicación de trabajo para poder llevar a cabo esta investigación.

Después de realizar diversas pruebas, modificando las variables y el número de neuronas, se ha considerado como adecuada una RNA de conexión total hacia adelante formada por tres capas, con un total de 20 neuronas.

La capa de entrada consta de 12 neuronas, una por cada variable seleccionada.

La capa oculta, o intermedia, consta de 7 neuronas.

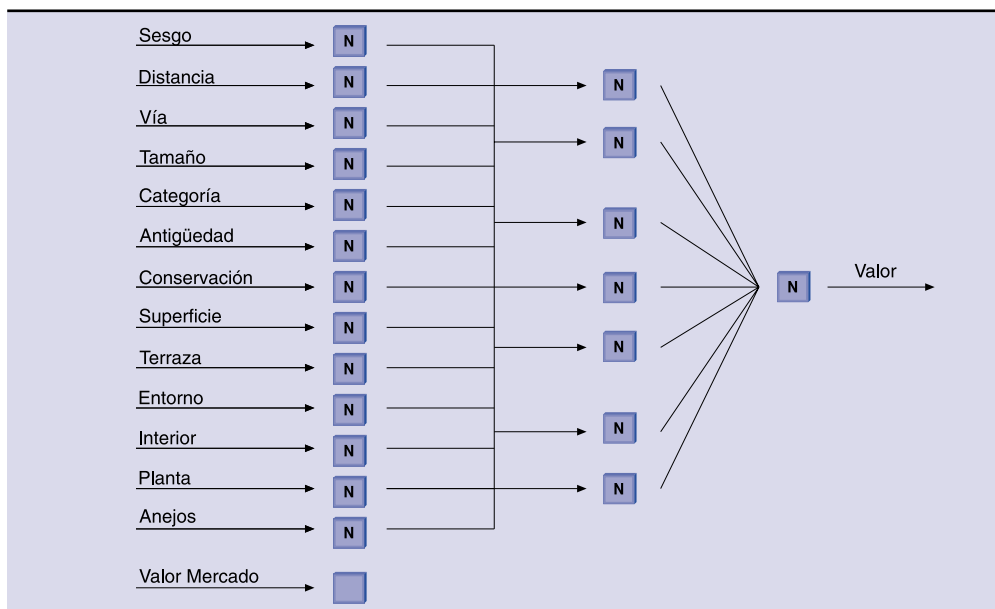
La capa de salida tiene una única neurona, que es la que produce como resultado el Valor calculado por la RNA.

Las variables seleccionadas no pretenden ser un juego definitivo para la valoración de la vivienda colectiva en Madrid, sino un conjunto de variables que permitan llevar a cabo una primera aproximación. Estas variables son:


1. Distancia: distancia del municipio, distrito o barrio al centro de la ciudad de Madrid.
2. Vía: vía de acceso al centro de la ciudad de Madrid. Se codifican las diferentes vías de acceso.
3. Tamaño: tamaño del municipio.
4. Categoría: categoría de la construcción.
5. Antigüedad: antigüedad de la construcción.
6. Conservación: estado de conservación de la construcción.
7. Superficie: superficie construida de la vivienda.
8. Terraza: superficie de la terraza.
9. Entorno: situación en el municipio, distrito o barrio
 - situación muy desfavorable 1
 - situación desfavorable 2
 - situación media 3
 - situación favorable 4
 - situación muy favorable 5
10. Interior: vivienda interior
11. Planta: número de planta
12. Anejos: codificación según nivel de anejos (jardines, piscina, etc.).

Además, se ha incluido una entrada de valor constante igual a "1" para formar el sesgo de cada neurona. Esta es una práctica frecuente en el diseño de las RNA, por la que existen pesos que marcan el sesgo propio de cada neurona, y que no son constantes, pues varían a lo largo del proceso de cálculo.

Gráfico 5
RNA para la valoración de la vivienda colectiva (Madrid)



La función de transferencia elegida para las neuronas es la función sigmoidea, que es la de uso más frecuente en las RNA. El Algoritmo de corrección es el de “retropropagación hacia atrás”.



Los parámetros con los que se ha trabajado son los habituales de las RNA: Ratio de Aprendizaje, Momento y Ruido de entrada.

El Ratio de Aprendizaje indica la parte del error que se corrige en cada acción de corrección. Un ratio del 0,1 significa que se

corrige un 10% del error detectado. Este es un parámetro fundamental de las RNA, pues en el aprendizaje hay que reducir el error poco a poco. Si se intenta reducir bruscamente, el comportamiento de la RNA puede ser inestable. En este ejemplo se han utilizado ratios entre 0,6 y 0.

El Momento es un parámetro que suaviza el proceso de corrección, de modo que cuando se detecta un error, en lugar de hacer la corrección de la parte de ese error que indica el Ratio de Aprendizaje, se realiza una corrección intermedia entre el error actual y el inmediatamente anterior. De este modo se consigue también que una muestra defectuosa no desvíe de forma substancial la dirección del aprendizaje. En este ejemplo se considera un Momento 0.

El Ruido de Entrada es un parámetro que deforma de modo aleatorio las variables en un porcentaje. Su objetivo es el de evitar que un grupo de muestras demasia-

do perfectas impidan que la RNA capte un modelo que sea generalizable. En este ejemplo el Ruido de Entrada se considera igual a 0, ya que por lo general se suele admitir que las muestras del mercado inmobiliario son “ruidosas” de por sí.

Para comprobar y detener el funcionamiento de la RNA se ha utilizado el coeficiente de referencia al mercado RM, como porcentaje entre el valor calculado por la RNA y el valor de mercado conocido de la muestra (un RM del 100% significa que el valor calculado y el valor de la muestra coinciden). El objetivo buscado es que la mediana de los RM de las muestras se situé en un entorno próximo al 100%, y que la dispersión de los RM de las muestras (Coeficiente de Dispersión) sea inferior al 10%.

Se ha utilizado un conjunto de 100 muestras de mercado de diversos municipios de la Región de Madrid. 85 muestras se utilizan para entrenamiento y 15 para comprobación. De todas formas, conviene comentar que para una RNA con 12 variables sería conveniente un conjunto de unas

250 muestras, 200 para entrenamiento y 50 para comprobación. Pero, dado el carácter de investigación de este trabajo, con 100 muestras ya se debería poder obtener un resultado interesante. Todas las muestras pertenecen al año 2002.

Una vez ajustada la RNA, los resultados obtenidos en la fase de entrenamiento son los siguientes: Mediana 100%, Dispersión 8%.

En el gráfico 6 se puede observar la dispersión final de las muestras una vez entrenada la RNA.

Podemos comparar este resultado con el que se obtendría de aplicar a este mismo conjunto de 85 muestras la Regresión Múltiple.

En este caso, con la Regresión Múltiple se consigue una mediana del RM también próxima al 100%, pero la Dispersión es del 15%, es decir 7 puntos más alta que la de la RNA.

En el gráfico 7 se pueden comparar estas dos dispersiones, y se observa cómo para la mayoría de las muestras el resultado de la RNA está más próximo a la línea del 100%.

Gráfico 6
Dispersión de las muestras. Fase de entrenamiento

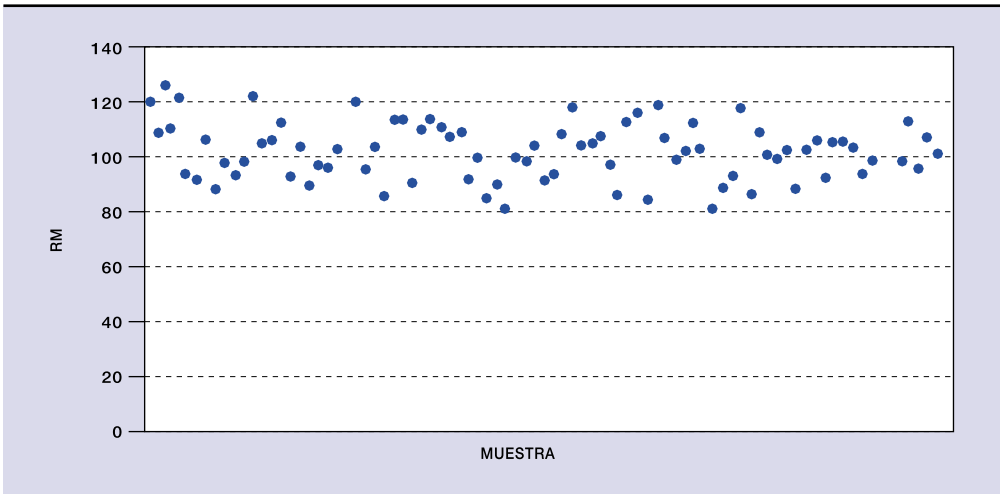



Gráfico 7
Comparación RNA - Regresión



Asimismo se observa cómo la Regresión Múltiple indica la existencia de dos Outliers, que sin embargo la RNA aproxima más a la línea del 100%.

En este ejemplo se cumplirían, por tanto, las dos ventajas que algunos investigadores han atribuido a las RNA frente a la Regresión Múltiple, y que consisten en una mayor precisión, y un mejor tratamiento de los Outliers. De todas formas, esto es un ejemplo concreto, y no se debe generalizar.

Una vez entrenada la RNA con las 85 muestras citadas, pasamos a la fase de comprobación con las 15 muestras restantes. En esta fase se aplica la RNA directamente a las muestras de comprobación, de las que también se conoce el valor de mercado, para ver si se mantienen unos buenos resultados con muestras que no han intervenido en el entrenamiento. En este caso el resultado es satisfactorio pues la RNA mantiene una Mediana del 100% y una Dispersión del 8% con las 15 muestras. En cuanto a la Regresión Múltiple, presenta con ellas una Mediana del 96% y una Dispersión del 14%. De todas formas,


como ya se ha comentado, se debe comprobar esta RNA con un número superior de muestras. Por lo general los indicadores suelen empeorar algo en la fase de comprobación.

Después de verificar que la RNA mantiene unos buenos resultados con las muestras de comprobación, ya se puede utilizar para valorar viviendas colectivas de las que no se conozca su valor. Se puede utilizar para hacer valoraciones individuales de viviendas concretas o bien para valoración masiva.

La RNA descrita se ha utilizado para valorar todas las viviendas colectivas de la Región de Madrid. El número de viviendas valoradas es de 1.893.000, distribuidas por todos los municipios de la Región, incluida la capital.

Para llevar a cabo la valoración masiva se ha utilizado un Gestor de Bases de Datos en el que se han incluido las 12 variables de la RNA para todas las viviendas, y se han programado las fórmulas del sistema ya descritas. El tiempo de valoración es de unos 15 a 20 minutos en un ordenador personal.

Gráfico 8
Valores según tamaño. Pinto



Los resultados obtenidos se muestran en los gráficos siguientes, y parecen indicar un nivel de aproximación a los valores de mercado bastante razonable, teniendo siempre presente el carácter de ensayo de este trabajo, así como el reducido número de muestras utilizado, y que son valores del año 2002.

En el gráfico 8 se pueden observar los resultados para el municipio de Pinto. En él se representa la distribución de valores por tamaño de las aproximadamente 10.000 viviendas colectivas del municipio.

Como puede apreciarse, la pendiente del perfil de distribución indica que los valores son proporcionalmente más bajos cuanto mayor es la superficie (es decir que un piso de 200 m² no vale el doble que uno de 100 m²). Esto puede apreciarse mejor en el gráfico 9.

Este gráfico se ha construido con viviendas nuevas de categoría 4 (intermedia) y situadas en la planta 2^a, para que no influyan en el resultado estas variables. Como

puede apreciarse, los valores unitarios disminuyen a medida que aumenta la superficie de la vivienda, según el perfil que la RNA ha captado con las muestras de entrenamiento. Hay que decir que este perfil no es un perfil simple, pues depende de la interacción de todas las variables, por lo que para cada municipio, entorno, categoría, etc., será diferente.

Otra variable interesante cuyo comportamiento se puede analizar es la planta. En el gráfico 10 se muestran los valores por planta de las viviendas de 85 m² de superficie y categoría 4.

Se puede ver cómo los valores van aumentando al subir de planta. La RNA ha captado un incremento de valor según la planta que tiene un perfil suave pero apreciable.

El gráfico 11 muestra la distribución de valores por tamaño de otros dos municipios de la Región: Tres Cantos y Villacañeros. Tres Cantos es un municipio de tamaño relevante, situado a unos 22 Km. de

Gráfico 9
 Pinto: Valores según tamaño. Planta 2ª, Categoría 4, Nueva

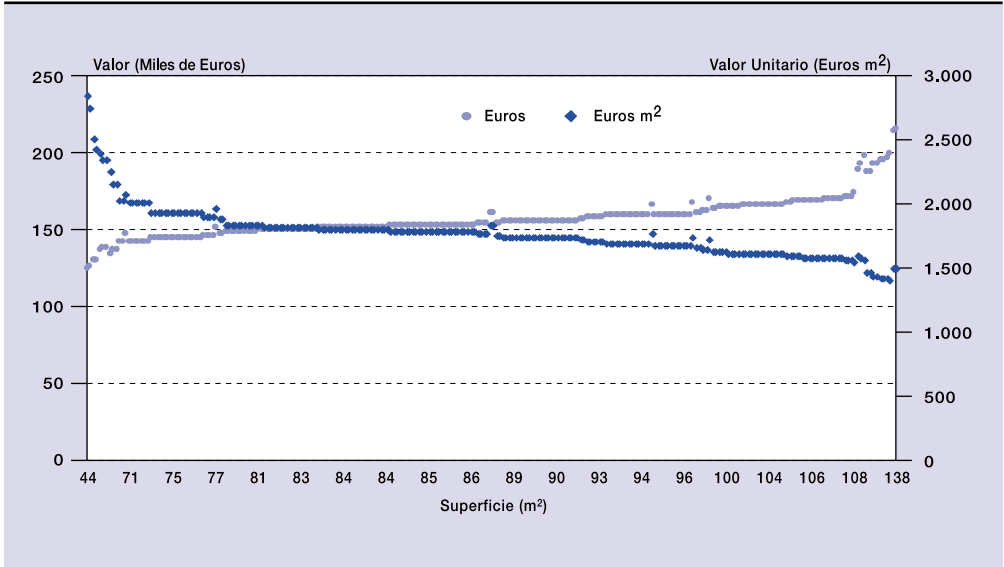


Gráfico 10
 Pinto: Valores por planta. Superficie 85 m², Categoría 4




Gráfico 11
Valores según tamaño. Tres Cantos y Villaconejos

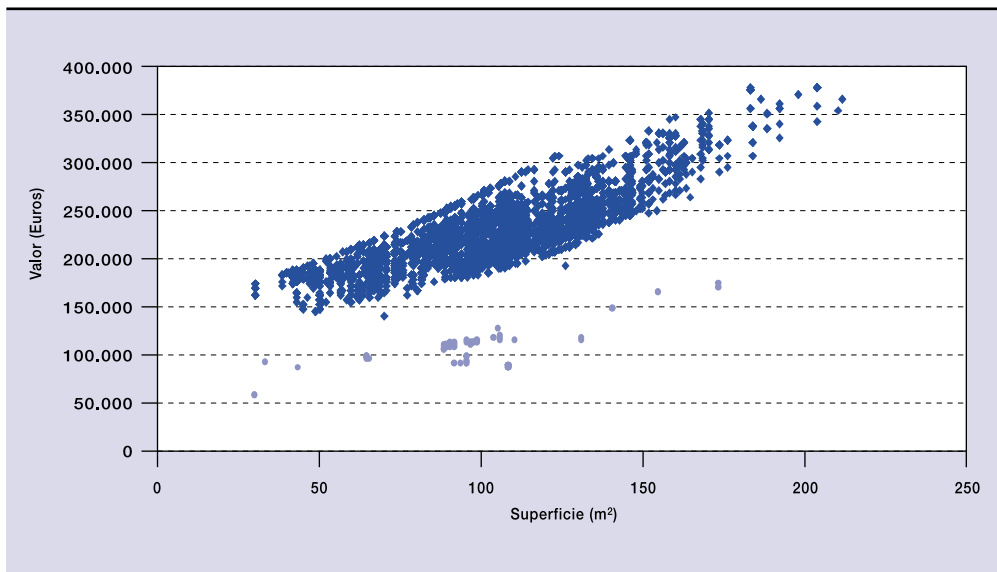



Gráfico 12
Valores según tamaño. C/ Velázquez y C/ Marcelo Usera



Madrid hacia el norte, y muy homogéneo, pues la práctica totalidad de sus edificios se han construido en los últimos 20 años, y son de categoría similar. Villaconejos es un municipio más pequeño y más alejado del área metropolitana de Madrid (unos 50 Km. hacia el sur), y en el que no abunda la vivienda colectiva.

Asimismo se puede analizar la distribución de valores de un determinado Distrito, Barrio, Urbanización o Calle. En el gráfico 12 se incluye a título de ejemplo la distribución de valores según tamaño de dos calles de Madrid: la calle Velázquez situada en la zona céntrica, y la calle Marcelo Usera situada en la zona sur.

A la vista de los resultados obtenidos, y teniendo siempre presente el carácter experimental de este trabajo, parece que las RNA son capaces de captar el comportamiento conjunto de las variables en el mercado inmobiliario, incluso en un ámbito territorial amplio, en donde los productos son más variados y las relaciones de variables son más complejas.

Bibliografía

MARGARITA M. LENK, ELAINE M. WORZALA and ANA SILVA (1996): "High-tech valuation: should artificial neural networks bypass the human valuer?"

FRANCISCO PIZARRO REDONDO: "El paradigma de las redes neuronales artificiales".

PETER ROSSINI (1998): "Using Expert Systems and Artificial Intelligence for Real Estate Forecasting".

PETER ROSSINI (2000): "Improving the Results of Artificial Neural Network Models for Residential Valuation".

RAVI MADAPATI (2002): "Artificial Neural Networks: A Primer".

MARCO AURELIO STUMPF GONZALEZ, LUCIO SOIBELMAN and CARLOS TORRES FORMOSO: "Explaining the Results in a Neural-Mass Appraisal Model".

JOHN D. HAYNES and CLARENCE NW TAN: "An Artificial Neural Network Real Estate Price Simulator".

CLARENCE NW TAN: "An Artificial Neural Networks Primer with Financial Applications Examples in Financial Distress Predictions and Foreign Exchange Hybrid Trading System". ■

