

## Un análisis del mercado de la vivienda a través de redes neuronales artificiales

\*CARIDAD Y OCERÍN, J.M., y \*\*CEULAR VILLAMANDOS, N.

*Dpto. de Estadística, I.O. Econometría y Org. Empresas. Universidad de Córdoba.*

Apartado de Correos: 3048 - 14080 CÓRDOBA

### RESUMEN

El análisis del mercado de la vivienda, como parte fundamental en el desarrollo de la Economía Urbana de una región y por agregación de un determinado país, se ha constituido en una de las principales líneas de investigación de la última década. Debido al continuo incremento de los precios en dicho mercado, se están manteniendo interesantes debates acerca de las causas de este pernicioso proceso y de las políticas a aplicar para mejorar el estado de bienestar social.

En los últimos años se están replanteando los trabajos de Rosen (1974), emergiendo un nuevo concepto de vivienda como conjunto de atributos que le confieren identidad propia, haciendo que unidades de igual precio puedan ser contempladas por oferentes y demandantes como bienes sustancialmente diferentes. Con este propósito, se introduce la metodología hedónica para analizar el precio de un bien en función de sus características, a través de la estimación de los precios implícitos de sus componentes.

El desarrollo de la Inteligencia Artificial permite la utilización de sistemas de redes neuronales como alternativa a los métodos econométricos de modelización tradicional. En el presente trabajo se pretende desarrollar una estructura del tipo *perceptrón multicapa* como herramienta de predicción del precio de la vivienda. La comparación de los resultados obtenidos con ambos modelos, muestra una considerable mejora en la precisión de las valoraciones con la utilización de sistemas neuronales artificiales.

**Palabras clave:** Economía Urbana; Precio vivienda; Redes neuronales; Modelos hedónicos.

### ABSTRACT

The real state market is a fundamental part of Regional Urban Economics, and it has been intensive research has been developed in the last decade. The increases in the house prices have originated a broad debate over its causes, and the policy necessary to increase the general well being. The classical S. Rosen (1974) paper consider a dwelling as a set of attributes that can be valued different by the consumers, through their hedonic prices. An alternative, based on A.I. developments is proposed: a multilayer perceptron neural network is used to estimate house prices. The results obtained in a case study show statistical advantages over the classical hedonic methodology, with an increased accuracy.

**Key words:** Urban economics; housing prices; neural networks; hedonic models.

Código UNESCO: 5302-02, 5312-03

Artículo recibido el 29 de noviembre de 1999. Aceptado el 28 de julio de 2000.

## I. La metodología hedónica.

En torno a los 60 se potencian las técnicas hedónicas que habían surgido con Waugh (1928) para el análisis de ciertos vegetales, y Court (1939) para el análisis del mercado automovilístico. A partir de los desarrollos de Lancaster (1966) y Muth (1969), emergen las primeras aproximaciones teóricas del enfoque hedónico aplicadas al mercado de la vivienda (Rosen, 1974).

Con el fin de explicar la heterogeneidad inherente de la vivienda, numerosos analistas del mercado inmobiliario han considerado dicho bien en términos hedónicos. En estos análisis, la unidad de vivienda pasa de considerarse un bien homogéneo e indivisible a conceptualizarse como una cesta de atributos individuales cada uno de los cuales contribuye a la provisión de uno o más servicios de vivienda.

El enfoque hedónico, en general, pretende determinar el precio de un bien en función de sus características por medio de la estimación de la ecuación de precios implícitos. Esta es la razón de su aplicación al estudio de la vivienda como un bien no homogéneo, además de multiatributo<sup>1</sup>. En esta línea, numerosos analistas del mercado de la vivienda consideran dicho bien en términos hedónicos, exponiendo que, si el mercado está en equilibrio, y si el modelo está bien formulado, la regresión hedónica estima el valor de mercado de cada uno de los servicios de vivienda conjuntamente transmitidos u ofertados por un arrendador.

Rosen desarrolla un modelo general para oferta y demanda de bienes heterogéneos. Establece que la ecuación hedónica representa una envolvente conjunta de una familia de funciones de valor y otra de funciones de oferta. Se define una función de demanda 'bid' para cada unidad de familia como el valor máximo que dicha unidad está dispuesta a pagar por la cesta de atributos que componen la vivienda<sup>2</sup>. Así, considera la vivienda descrita por un conjunto de características medidas de manera objetiva a partir de la utilidad que cada unidad familiar confiere a dicho atributo de la cesta. Además, se establece que dicha función  $V = V(z_1, z_2, \dots, z_k, y, v)$ , puede estar afectada por los niveles de renta ( $y$ ), y por las preferencias de los demandantes ( $v$ ).

Considerando que la función de utilidad es estrictamente cóncava, la función 'bid' para el conjunto de características del inmueble aumentará si se produce un incremento en la utilidad de las mismas, pero dicho incremento será menos que proporcional.

Derivando la función de valoración con respecto a cada característica,  $\partial V / \partial z_i$ , se obtiene el valor de precios implícitos para el conjunto de atributos demandados por la unidad familiar.

1. Follain, J.R. y Jiménez, E. (1985a), pp. 54-80.

2. Rosen, S. (1974), pp. 34-55.

Paralelamente, se define una función de oferta,  $O = (z_1, z_2, \dots, z_k, N, C)$ , como indicativo del valor mínimo a partir del cual un oferente está dispuesto a aceptar la venta de un inmueble. Presuponiendo la conducta maximizada del oferente, la función de oferta dependerá del conjunto de atributos, del número de viviendas vendidas ( $N$ ) y del coste de producción ( $C$ ).

Considerando la función de beneficios de los oferentes estrictamente convexa, ante incrementos en la valoración del conjunto de atributos ofertados ésta puede permanecer constante o incrementar su valor. Diferenciando dicha función con respecto a un atributo cualquiera,  $z_i$ , obtenemos los precios implícitos ofertados para cualquier atributo,  $\partial O / \partial z_i$ .

El mercado en equilibrio se define por la intersección entre ambas funciones de oferta y de demanda para un conjunto de atributos dados. Así, la conducta maximizada de consumidores y productores expuesta anteriormente, genera un precio que actúa como parámetro en las decisiones de los agentes económicos. Este representa por el lado de la demanda, el precio máximo que los consumidores están dispuestos a pagar por un conjunto determinado de características de la vivienda. Si dicho valor es igual o superior al precio mínimo a partir del cual los oferentes están dispuestos a vender una vivienda con ese conjunto determinado de características, se realiza la venta efectiva de la misma. Será necesario por tanto que,  $D = O$  para todo  $i$ . Así, los  $n$  mercados para los  $n$  conjuntos de atributos formarán un sistema de  $2n$  ecuaciones simultáneas y con una solución que garantiza el precio de equilibrio.

## II. Metodología hedónica en la valoración de viviendas: Problemas metodológicos

Los datos que caracterizan una vivienda son en parte numéricos y en parte en atributos cualitativos. Se hace necesario una transformación de las variables no numéricas por medio de índices que recogen determinadas características, y que permitan su interpretación cuantitativa. Para ello se recurre a la opinión de los expertos de las agencias de la propiedad como herramienta para contrastar la adaptación a la realidad de dichos índices<sup>3</sup>. Además, y con el fin de homogeneizar los índices para que a priori todos tengan la misma importancia relativa, se determina un rango común  $[0,1]$ . Así, valores de los índices próximos a la unidad representan situaciones óptimas de las variables que componen dicho índice, frente a valores cercanos a cero que determinan situaciones desfavorecidas de dichas variables.

Los índices manejados son los siguientes<sup>4</sup>:

---

3. Caridad, J.M. (1997), pp. 32.

4. Caridad, J.M. y Ceular, N. (2000a), pp. 4-6.

- **Índice de Conservación:** Es el estado general de la vivienda a primera vista, recogiendo la imagen que proporciona el inmueble cuando se visita. Para su elaboración, se han tenido en cuenta las variables denominadas de *Estado* (estado general de la cocina, de los cuartos de baño y del pavimento) y las variables denominadas de *Reforma* (Reforma realizadas en fontanería, electricidad y pavimento).
- **Índice de Servicios:** Recoge determinados complementos de la vivienda -posesión de lavadero y de despensa-.
- **Índice de Situación:** Refleja la situación de la vivienda con relación al edificio donde la misma se ubica. Para su elaboración se han tenido en cuenta la planta -baja, intermedia, alta- donde la vivienda se sitúe, la disponibilidad de ascensor, y la orientación de la misma (exterior), i.e. las vistas que dicho inmueble posea.
- **Índice Arquitectónico:** Este índice recoge las cualidades del edificio donde la vivienda se encuentra situada. Para su elaboración se considera el año de construcción del mismo, el estado del portal, la disponibilidad de zonas ajardinadas y piscina en las zonas comunes, y por último, la posesión de antena parabólica.
- **Índice Ubicación:** Se considera la situación geográfica de la vivienda con relación a la ciudad. Para tal fin se utiliza la situación del edificio dentro del barrio donde el mismo esté ubicado, ponderado por la situación del barrio con referencia a la ciudad y a los niveles de renta de cada barrio.

**Tabla 1. Indicadores sintéticos aritméticos**

DENOMINACIÓN	VARIABLES UTILIZADAS PARA SU CONSTRUCCIÓN
<b>Índice de Conservación</b>	Estado de conservación (cuartos de baños, cocina y pavimento). Reformas realizadas (fontanería, electricidad y cerramientos).
<b>Índice de Servicios</b>	Disponibilidad de lavadero. Disponibilidad de despensa.
<b>Índice de Situación</b>	Planta. Disponibilidad de ascensor. Orientación de la vivienda (vistas).
<b>Índice de Arquitectónico</b>	Fecha de edificación. Estado del portal. Zonas ajardinadas y Piscina. Antena parabólica / cable.
<b>Índice de Ubicación</b>	Barrio donde se ubica el edificio. Situación dentro del barrio. Nivel de renta del barrio.

La estimación de modelos hedónicos conlleva una serie de problemas entre los que se pueden destacar en primer lugar la existencia de multicolinealidad entre las variables pre-determinadas del modelo, debido a las características intrínsecas de dichas variables<sup>5</sup>. Di-

5. Caridad J.M. y Brañas, P. (1997), pp. 8-14.

cha relación entre las variables explicativas -normalmente de tipo aproximado-, produce aumentos en los errores estimados debido a imprecisiones en la estimación. La interpretación de los precios hedónicos se ve afectada por las interrelaciones entre las variables que definen cada vivienda dificultando por ende, la valoración de cada uno de sus atributos. Otro problema econométrico asociado al planteamiento general de los modelos hedónicos, es el relativo al enfoque uniecuacional y a la posible no identificabilidad de las ecuaciones del mismo. En lo que al análisis de las perturbaciones aleatorias se refiere, el estimar con datos de corte transversal, conlleva la posible presencia de heterocedasticidad, con el consiguiente incumplimiento de las propiedades probabilísticas de los estimadores obtenidos. Por último, la utilización de la forma funcional adecuada para estimar la ecuación hedónica, la especificación de la ecuación -que puede ser de tipo lineal o linealizable-, pudiendo introducir interacciones de las variables.

### III. Sistemas neuronales artificiales como alternativa a la metodología hedónica

Los orígenes de los Sistemas Neuronales Artificiales se remontan a los trabajos de Mc. Culloch y Pitts (1943). En esencia, dichos sistemas tratan de mimetizar la estructura computacional del sistema nervioso humano con el fin de resolver problemas de carácter cognitivo que no son fáciles de programar en modo algorítmico. Sus primeras aplicaciones fueron la modelización de distintos procesos de la actividad neurobiológica. Más tarde se comienza a investigar su aplicabilidad al análisis de datos y al control y proceso de señales en tiempo real, que hoy día pueden considerarse como sus principales campos de aplicación<sup>7</sup>.

Rumelhart, D.E. y McClelland, J.L. (1986) definen la Red Neuronal Artificial como una red compuesta de varios operadores simples -elementos de proceso o nodos-, dotados de una pequeña cantidad de memoria. Las unidades están conectadas mediante canales de comunicación unidireccionales -o axones-, que transportan datos numéricos -no simbólicos-. Los nodos únicamente operan sobre sus datos locales y sobre las entradas que reciben a través de los axones. Así, todo modelo neuronal queda caracterizado por ocho componentes básicos<sup>8</sup>: a) Un conjunto de unidades de procesamiento  $\Omega = \{u_1, u_2, \dots, u_n\}$ , o conjunto de elementos simples e interconectados -neuronas- que procesan la información y que suelen disponerse en capas o niveles estructurados jerárquicamente; b) Un estado de activación, que en cada instante  $t$  representa el nivel de activación de cada neurona  $u_j$  a través

6. Goddman y Kawai (1984), Graves y otros (1988) y Can (1992).

7. Caridad, J.M. y Ceular, N. (1999).

8. Martínez de Lejarza, I. (1996). pp. 4.

de un valor de activación real; c) Unas salidas de las unidades de activación, que en cada instante determinarán la señal que cada neurona  $u_j$  envía a sus vecinas; d) Un patrón de conexión, que establecerá la topología propia de la red, su eventual jerarquización por capas y la intensidad y el sentido de las distintas interconexiones. El patrón se representa por una matriz de pesos o ponderaciones sinápticas ( $W$ ), en la que  $W_{ji}$  representa la intensidad y el sentido con el que la salida de la neurona  $i$ -ésima afecta a la activación de la neurona  $j$ -ésima.

En todo modelo neuronal es necesario disponer de una regla de propagación que combine las salidas de cada neurona con las correspondientes ponderaciones establecidas por el patrón de conexión para especificar como se valoran las entradas que recibe de cada neurona. El efecto global sobre una neurona  $u_j$  de todas las demás, puede considerarse aditivo y constituye la entrada neta:  $net_j = \sum w_{ji} o_i(t) = \sum w_{ji} f(a_i(t))$ . La regla o función de activación, será una función que, a partir del estado actual de activación de una neurona y de su entrada neta, determinada por el patrón de conexión y por la regla de propagación, evalúe el estado de activación subsiguiente:  $a_j(t+1) = F(a_j(t), net_j(t))$ ; Una regla de aprendizaje, procedimiento por el cual se procede a la modificación del patrón de conexión; y por último, Una representación de ambiente.

A partir de lo visto hasta el momento se puede deducir que dependiendo del modelo de neuronal concreto que se utilice, de la arquitectura o topología de conexión planteada, y del algoritmo de aprendizaje, surgirán multitud de modelos de redes neuronales.

Una clase especialmente importante de modelos de redes es el Perceptrón Multicapa, (MLP). Debido a su interés histórico, generalidad y al ilustrar una amplia clase de aspectos que aparecen con frecuencia en todo el campo de las redes neuronales (clasificación, aproximación lineal, etc.), se han convertido en los modelos más útiles desde el punto de vista de las aplicaciones prácticas. Los orígenes del Perceptrón Multicapa se remontan a los inicios de los cincuenta. Rosemblatz (1952) introduce el perceptrón simple, un modelo unidireccional compuesto por dos capas de neuronas, una de entrada y otra de salida. La importancia del perceptrón simple radicaba en su carácter de dispositivo entrenable pues el algoritmo de aprendizaje permitía que se determinaran automáticamente los pesos sinápticos que clasificaban un conjunto de patrones etiquetados<sup>9</sup>. El perceptrón multicapa unido al algoritmo de aprendizaje propagación hacia atrás es una estructura más grande y compleja, por lo que sus capacidades operativas son mucho mayores.

Los nodos se agrupan por capas conectándose los nodos de una capa con los de la siguiente, y así sucesivamente. Se trata de una red *feedforward* en la cual, las señales se

9. Martín del Brío, A. (1997) pp. 51.

propagan únicamente hacia delante. La capa de entrada desempeña una única función: transmitir las señales de entrada al resto de la red. La capa de salida proporciona el vector salida de la red, i.e., el resultado. Serán las capas intermedias, capas ocultas, las que procesen información extrayendo los rasgos característicos de las señales de entrada. Mediante un proceso de entrenamiento (algoritmo de propagación hacia atrás) se obtienen un conjunto óptimo de pesos sinápticos que permite el acercamiento de la salida deseada.

#### IV. Modelo hedónico versus red neuronal: un caso práctico

Con el fin realizar un análisis del mercado de la vivienda en la ciudad de Córdoba, se confecciona una encuesta que se distribuye a las Agencias de la Propiedad Inmobiliaria. Se obtiene información de las características internas y externas de 1057 expedientes de viviendas vendidas durante el año 1997 en la ciudad. El trabajo de campo se realiza durante el primer trimestre de 1998. Las variables finalmente recogidas se reflejan en la tabla 2.

Tabla 2. Clasificación de las variables

INTERNAS DE LA VIVIENDA			EXTERNAS DEL EDIFICIO	
<b>BÁSICAS</b>	Superficie (metros cuadrados útiles) Número de dormitorios Número de Armarios empotrados Número de Cuartos de Baño Climatización Lavadero Despensa Trastero		<b>GENERALES</b>	Estado del edificio Estado del portal Acceso directo a garaje
			<b>ACCESIBILIDAD</b>	Ascensor Planta en el edificio
			<b>EXTRAS</b>	Piscina Parabólica / Cable
<b>GENERALES</b>	<b>ESTADO</b>	Estado de la cocina Estado de los baños Estado del pavimento	<b>LOCALIZACIÓN</b>	Barrio Situación en el barrio
	<b>REFORMAS</b>	Reformas agua Reformas cerramientos Reformas inst.eléctrica		
<b>ORIENTACIÓN</b>	Exterior			
<b>ECONÓMICAS</b>	Gastos de comunidad Precio de mercado			

Se procede a realizar una breve descripción de algunas de las variables de mayor relevancia obtenidas en la muestra.

**Tabla 3. Descriptiva Precio de Mercado (miles de ptas.)**

PRECIO MERCADO (miles ptas)	FRECUENCIA	(%)
(2000, 4560)	28	2.50
(4560, 7120)	161	14.90
(2000, 14800)	818	70.71
(7120, 9680)	272	21.76
(9680, 12240)	219	14.62
(12240, 14800)	138	16.94
(14800, 17360)	107	9.43
(17360, 19920)	61	5.37
(14800, 27600)	265	24.69
(19920, 22480)	43	3.79
(22480, 25040)	37	3.26
(25040, 27600)	17	2.84
(27600, 40400)	41	3.60
(40400, 66000)	11	1.02
<b>TOTAL DE CASOS</b>	<b>1135</b>	







Tabla 4. Descriptiva Número de Dormitorios

NÚMERO DE DORMITORIOS	FRECUENCIA	(%)
0	1	0,09
1	45	3,93
2	131	11,54
3	552	48,63
4	350	30,84
5	49	4,32
6	6	0,62
TOTAL	1134	



### Modelo Hedónico

Para la obtención de la ecuación hedónica que mejor explique el precio de la vivienda cordobesa en función de sus características, se realizan numerosas estimaciones combinando todas las variables explicativas. De todos los modelos obtenidos, se selecciona, a través del proceso de validación la ecuación que a continuación se presenta (1). En dicha ecuación el precio de la vivienda queda finalmente explicado por la superficie, interacción número de dormitorios con número de cuartos de baño, aire acondicionado, e índice de ubicación.

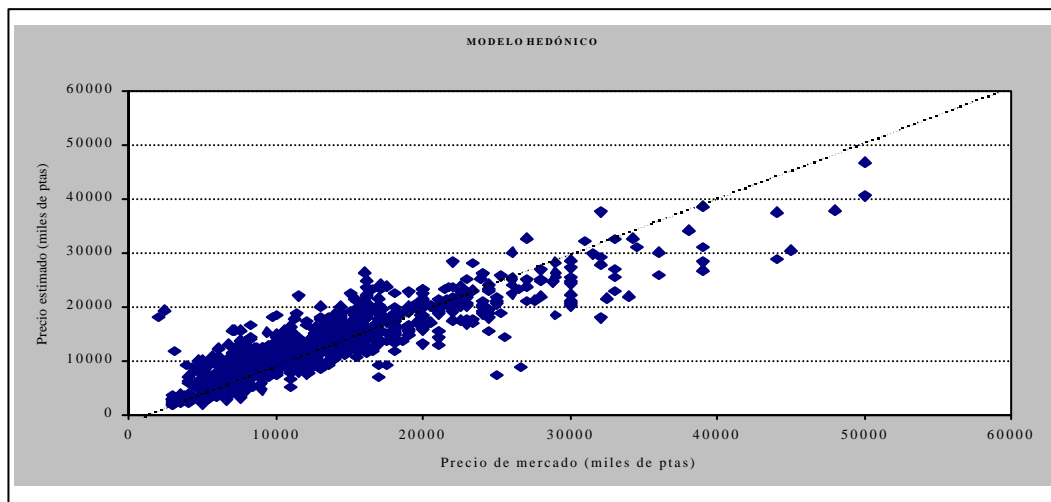
$$Prècio_i = 4613.304 + 88,236 Sup_i + 341,608 NDr_i NB\bar{n}_i + 1303,333 Air_i + 6889,106 \acute{E}Ubicacion_i \quad (1)$$

(333,122)
(3.716)
(47,658)
(126,234)
(447,232)

La contrastación de los tests usuales, incluyendo el test de estabilidad de Chow para los coeficientes es correcta. El índice de condición para la multicolinealidad es  $k = 46,79$ , y el coeficiente de determinación,  $R^2 = 0,613$ . El error cuadrático medio  $E.C.M. = 3552.12$  y el porcentaje de error medio absoluto es 20.44% sobre el precio real de mercado. El índice de Theil es 0,112: con un componente de sesgo prácticamente nulo; la proporción de varianza 0,059 y la de covarianza 0,941.

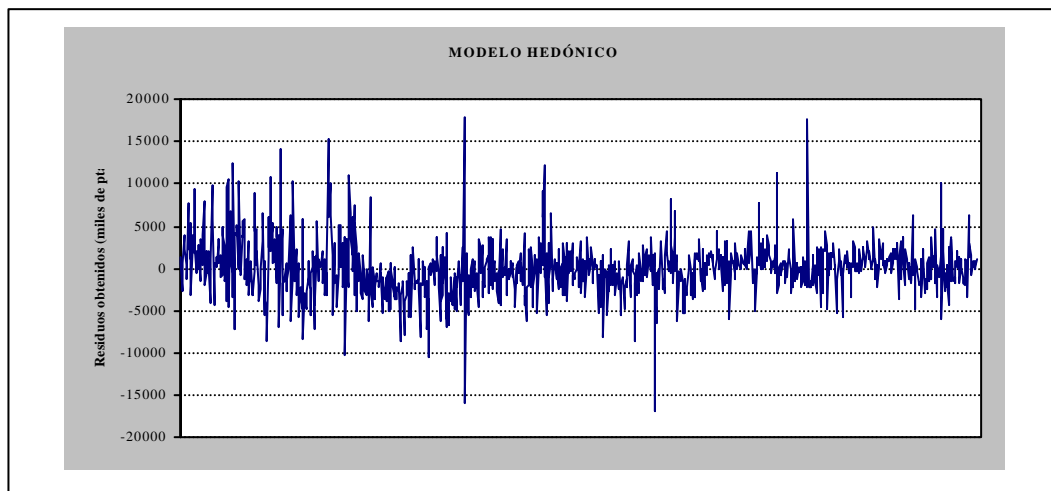
Los precios estimados con el modelo hedónico seleccionado se comparan con los precios reales obtenidos en la muestra. En el gráfico siguiente se presenta el resultado de la dicha comparación.

**Gráfico 1. Precio real vs. Precio estimado (miles de ptas.)**



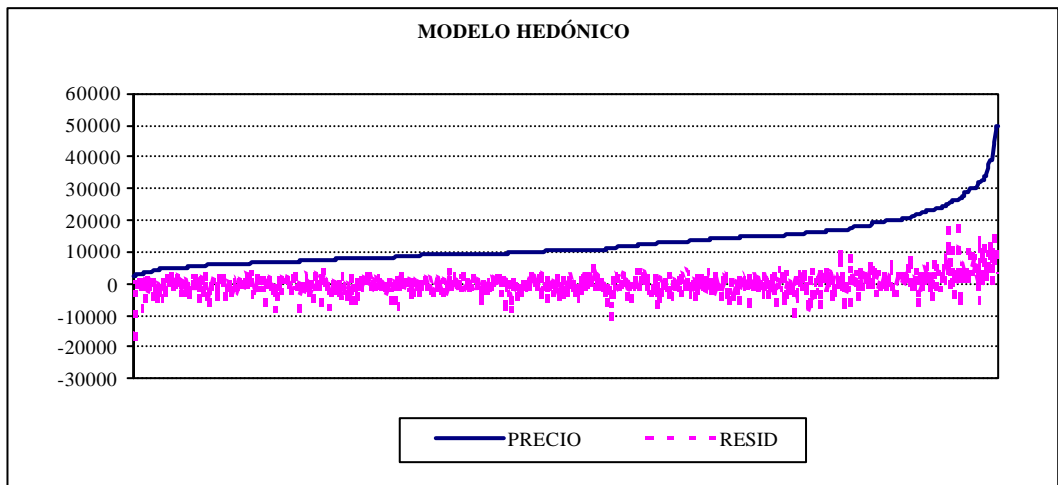
Como se observa en el gráfico, la mayoría de las observaciones se aproximan a la bisectriz del primer cuadrante, exceptuando las observaciones correspondientes a las viviendas de precios más elevados en las que el modelo proporciona valores estimados inferiores al valor de mercado. En vista de los resultados, se procede a representar los residuos del modelo para evaluar su comportamiento.

**Gráfico 2. Residuos obtenidos (miles de ptas.)**



A partir de los gráficos de los errores, se puede observar un proceso de infravaloración en aquellas viviendas de precios más elevados, percibiendo una distribución de errores claramente asintótica hacia la derecha. Así, en el siguiente gráfico, se detecta claramente que para las viviendas más caras, el error obtenido es mayor, y además que este último se encuentra por encima del eje de abscisas, lo que ratifica el proceso de infravaloración sistemática del modelo de regresión anteriormente citado.

**Gráfico 3. Precio Real y Residuos (miles de ptas.)**



### Modelo de red neuronal artificial

El trabajar con redes del tipo perceptron multicapa presenta una serie de cuestiones previas que se deben tener en cuenta a la hora de determinar la estructura óptima. Así, se mantienen unas restricciones de carácter estructural de la red como son la imposibilidad de conexión con capas anteriores, y de conexión entre neuronas de una misma capa, existencia de una sólo capa de entrada y otra de salida, etc.

Otro problema que se plantea en este tipo de redes es la selección del número de capas ocultas de la red y el número de neuronas por capa. Así, el número de nodos que forman las capas ocultas debe de ser lo suficientemente elevado para que permita la solución de problemas complejos, pero no tan elevado que la estimación de los pesos no resulte fiable para el conjunto de patrones de entrada. Además, un número excesivo en cualquier capa puede generar ruido, pero se puede conseguir una mayor tolerancia a fallos<sup>10</sup>.

10. Bonilla, M.(1997), pp.19

El siguiente aspecto es la división de la muestra al azar en dos grupos: el primero de ello se tomará como patrón ejemplo para entrenar la red, y el segundo se utilizará para comprobar la eficiencia de la misma. La correcta selección de la muestra será uno de los principales factores que determinarán el grado de eficiencia de la red. Con este fin, y al no existir un único modelo de vivienda debido a que las características de las viviendas varían de un inmueble a otro, ambas muestras debían recoger las distintas categorías de pisos que se pudieren dar. Se procede a seleccionar aleatoriamente, a partir de estratos de precio y barrio 630 viviendas que determinan el patrón de aprendizaje, utilizando las restantes 80 - 12% de la muestra- para la validación de la red y poder así evaluar su eficiencia.

Considerando todas estas cuestiones previas se diseña la red comenzando por la elección de un vector de señales de entrada con sus correspondientes salidas deseadas, e introducción de dicho vector en la red. Dicha información se propagará hasta la capa superior obteniendo el vector salida. Este proceso se realizará mediante la función de activación que produce la transformación de las de las entradas netas de cada nodo de una misma capa en salidas de nodos de dicha capa a la siguiente, constituyendo así, las entradas de la capa superior. Una vez realizado el proceso con los  $n$  vectores de entradas se procede a calcular la salida global de la red, y por diferencia con la salida deseada se obtiene el error global por unidad de salida. A continuación se determina la contribución relativa de los nodos a dicho error. Para determinar la dirección en la que dichos pesos serán modificados se procede a calcular el gradiente de la señal de error (parcial de la función de error con respecto a los pesos) y éstos se modifican de manera que se minimice dicho gradiente. Este proceso se repite para cada vector del conjunto de entrenamiento hasta que el error global obtenido sea mínimo.

Mediante el desarrollo de este comportamiento se consigue la autoadaptación de la red, así, la red habrá se provee de una representación interna y externa permitiendo que cuando se le presente una nueva entrada, pueda proporcionar una salida adecuada, es lo que se denomina capacidad de generalización.

En lo que a la arquitectura se refiere se diseñan numerosas redes combinado arquitecturas, funciones de aprendizaje y algoritmos de entrenamiento. Finalmente, se selecciona una red de propagación hacia atrás (backpropagation) con conexiones estándar, cada nivel conectado con el inmediatamente anterior, del tipo 5:14s:14s:1. Es decir, una red con cuatro neuronas de entrada -las mismas variables explicativas utilizadas en la ecuación hedónica- más la tendencia o bias, catorce neuronas en cada una de las dos capas intermedias ocultas, y una neurona de salida -precio de la vivienda-. Las funciones de activación en las neuronas de las capas ocultas son de tipo sigmoidal o logística<sup>11</sup>. Con respecto a esto último, indicar que la utilización de funciones de activación lineales, tangenciales (tangente hiperbólica),

---

11.  $f(x) = 1/(1 + \exp(-x))$

gaussiana, etc<sup>12</sup>, sin embargo fue con la función de tipo sigmoïdal con la que se obtienen mejores resultados en este caso. En lo que a la determinación del algoritmo de entrenamiento, se selecciona el método de los momentos por ser el que mejor resultados ha producido en esta aplicación. El tiempo de entrenamiento o aprendizaje de la red finalmente seleccionada fue de 5 horas<sup>13</sup>.

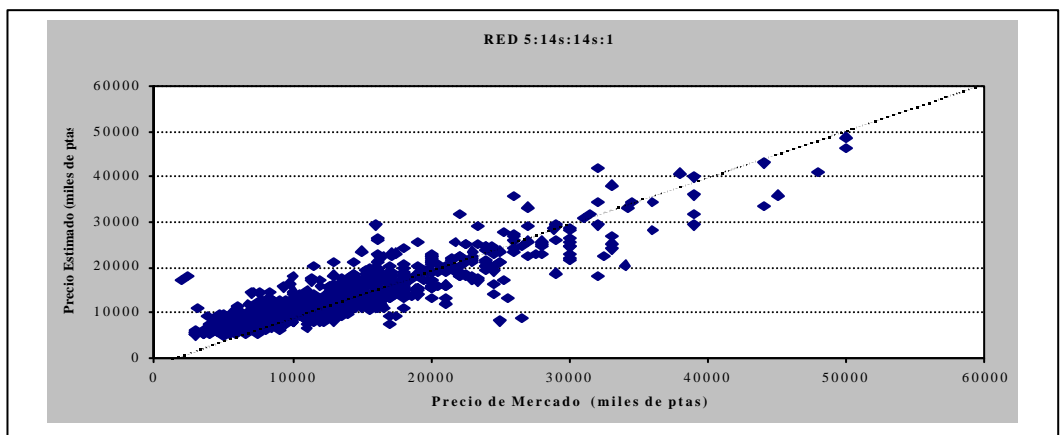
En la tabla siguiente se presentan los resultados obtenidos en los procesos de validación del modelo hedónico y de la red neuronal. Se puede apreciar una notable mejoría en las estimaciones del precio de la vivienda utilizando dicha red, en donde el error cuadrático medio alcanzado es considerablemente inferior al obtenido con la ecuación. Se ha alcanzado un  $R^2 = 0.8225$ . El error cuadrático medio ECM = 2650.67 en miles de pesetas y el porcentaje de error medio absoluto es 17.30% sobre el precio real de mercado.

**Tabla 5. E.C.M. y R Cuadrado**

	<b>E.C.M. VALIDACIÓN</b>	<b>R CUADRADO</b>
MODELO HEDONICO	3552.12	0.613
RED NEURONAL 5:14s:14s:1	2650.67	0.822

Se procede a representar un gráfico comparativo del precio de mercado con el estimado en la red. Como se observa, el ajuste a la bisectriz del primer cuadrante es muy alto, incluso en las observaciones, i.e. viviendas, con precios elevados.

**Gráfico 4. Precio Real vs. Precio Estimado (miles de ptas.)**



12. Freeman y Skapura (1993), pp.120

13. Pentium III a 450MHz, 64 MB de memoria.

## V. Conclusiones

A partir de los resultados obtenidos se observa que para la determinación del precio de la vivienda cordobesa, la red neuronal utilizada presenta mayor poder de predicción que el modelo hedónico. Además, para las observaciones de viviendas con precios elevados los valores de precio proporcionados resultan sumamente inferiores a los reales

Frente a la posibilidad que las redes ofrecen de introducir como inputs las variables originales -mediante previa estandarización- el proceso de estimación de modelo hedónico necesita de la generación de índices lo que conlleva pérdida de información, y la consiguiente dificultad en la interpretación de los resultados.

Los sistemas neuronales poseen flexibilidad para adaptarse a cambios que se presenten en el entorno. Así, no necesitan ser reprogramados sino que solamente se procede a un reajuste en los pesos de los mismos. Poseen capacidad de extracción para extraer las características fundamentales dentro de un gran volumen de datos, procediendo a la filtración de la información que pudiera resultar redundante.

Por último, destacar que la red presenta un importante inconveniente. En virtud de su particular procesamiento, es difícil validar los resultados en las capas intermedias, además, en principio se carece de modelo donde se puedan realizar interpretaciones económicas sobre los coeficientes obtenidos. Con respecto a este último aspecto, decir que si bien, dichos coeficientes son claramente obtenidos en la ecuación hedónica, tampoco su interpretación resulta del todo correcta puesto que los componentes de la vivienda no aparecen de forma individual sino formando parte de un todo. Por tanto, no parece correcto hablar de precios implícitos del mismo. Este inconveniente, aún sin menospreciarlo, es superado por los excelentes resultados de las redes frente a los obtenidos utilizando el modelo hedónico tradicional.

## Bibliografía

- BONILLA, M<sup>a</sup> y PUERTAS, R. (1997): «Análisis de las redes neuronales: aplicación a problemas de predicción y clasificación financiera». *Quaderns de Treball* 43. Departamento de Economía Financiera y Matemática. Universidad de Valencia.
- CARIDAD, J. M. y BRAÑAS, P. (1997): «*New applications in urban economics through Hedonic Price Models*». *37th European Congress of the Regional Science Association*. Italia.
- CARIDAD, J. M. y CEULAR N. (1999): «Hedonic modelling and alternative neural networks techniques in the real state market». Academy of Sciences. *International 30th Anniversary Session of Scientific*. Russia (Moscow).
- CARIDAD, J.M. y CEULAR, N. (2000<sup>a</sup>): «*Redes neuronales vs. Modelos hedónicos en problemas de valoración urbana*». *Revista de Estudios Empresariales. Monográfico Economía Urbana*.

- CARIDAD, J.M. y CEULAR, N. (2000<sup>b</sup>): «*Neural networks vs. Hedonic model in the estimation of real state prices: a case of study*». *Urban Studies* (en evaluación).
- COURT, A.T. (1939): «Hedonic Price Indexes with Automotive Examples, Dynamics of Automobiles Demand». *General Motors Corporation*, New York, pp. 99-117.
- FERNÁNDEZ, P; CARIDAD, J.M. y CEULAR, N. (1998): «Análisis de los modelos de localización de viviendas en la ciudad de Córdoba: un enfoque multivariante». *XII Reunión de ASEPELT*. España
- FOLLAIN, J.R. y JIMÉNEZ, E. (1985<sup>a</sup>): «Estimating the Demand for Housing Characteristics: A Survey and Critique». *Regional Science and Urban Economics*, 15, pp. 77-107.
- FOLLAIN, J.R. y JIMÉNEZ, E. (1985<sup>b</sup>): «The demand for Housing Characteristics in Developing Countries». *Urban Studies*, 22 (5), pp. 421-432.
- FREEMAN, J. y SKAPURA, D.M. (1993): *Redes neuronales algoritmos, aplicaciones y técnicas de programación*. Ed. Wilmington Addison-Wesley Diaz de Santos, 26-241.
- GOODAMN, A.C. Y KAWAI, M. (1984): «Functional form and rental housing market analysis», *Urban Studies*, 21, 367-376.
- GRAVES, P *et al.* (1988): «The Robustness of Hedonic Price Estimation: Urban Air Quality». *Land Economics*, 64 (3), pp. 220-223.
- LANCASTER, K.J. (1966): «A New Approach to Consumer Theory». *Journal of Political Economy*, 74, pp. 132-157.
- MARTÍN DEL BRÍO, A. y SANZ DE MOLINA, A. (1997): *Redes Neuronales y Sistemas Borrosos*. RaMa.
- MARTÍNEZ DE LEJARZA y ESPARDUCER, I. (1996): «Redes neuronales auto-organizadas y clustering: Una aplicación a la agrupación Económica-Funcional de las Entidades de Población». *Universidad de Valencia*. Documento de trabajo, 27.
- MUTH, R.F. (1969): *Cities and Housing*. University Press, Chicago.
- ROSEN, S. (1974): «Hedonic Prices and Implicit Markets: Product Differentiation in Pure Competition». *Journal of Political Economy*, 82, pp. 34-55.
- ROSENBLATT, F. (1958): «The Perceptron: A probabilistic model for information storage and organization in the brain». *Psychological Review*, 65, pp. 304-408.
- RUMELHART, D.E.; HINTON, G.E. y MCCLELLAND, J.L. (1986): *Learning representations by backpropagation*. *Nature*, 323, pp. 533-536.