

02-033

### MODEL OF NEURAL NETWORK APPLIED TO THE VALUATION OF HABITABILITY ADAPTATION ACTIONS IN REAL ESTATE ASSETS

Bienvenido-Huertas, David<sup>(1)</sup>; Fernández-Valderrama, Pedro<sup>(1)</sup>; Moyano, Juan<sup>(1)</sup>; Rico,  
Fernando<sup>(1)</sup>; Marín, David<sup>(1)</sup>

<sup>(1)</sup>Universidad de Sevilla

Nowadays, one of the main sector with the greatest demand in the real estate sector is the management of real estate assets. In this regard, the adequacy of the existing real estate stock is a broad field of work that ranges from technicians to operators. The habitability adaptation process of these assets is an activity with a large consumption of temporary resources and involves a complex organization of tasks that makes the process of prioritizing the actions difficult. Because of this circumstance, there are techniques of artificial intelligence, such as artificial neural networks, which can facilitate the analysis and assessment process. In this work, a multilayer perceptron is proposed for one of the most numerous types of real estate assets: dwellings. For this purpose, a total of 200 different dwellings are analysed, which are used for the training and validation of the model. The results allow to predict with a high degree of adjustment the priority of action and the estimated amount of the habitability adaptation works.

**Keywords:** *artificial neural network; multilayer perceptron; real estate asset; dwelling*

### MODELO DE RED NEURONAL ARTIFICIAL APLICADO A LA VALORACIÓN DE ACTUACIONES DE ADECUACIÓN DE HABITABILIDAD EN ACTIVOS INMOBILIARIOS

En la actualidad, uno de los principales sectores con mayor demanda en el sector inmobiliario es la gestión de los activos inmobiliarios. En este sentido, la adecuación del stock inmobiliario existente supone un campo de trabajo amplio que abarca desde técnicos hasta operarios. El proceso de adecuación de habitabilidad de estos activos constituye una actividad con un gran consumo de recursos temporales e implica una compleja organización de tareas que dificulta el proceso de priorizar las actuaciones. Ante esta circunstancia, existen técnicas de inteligencia artificial como las redes neuronales artificiales, que pueden facilitar el proceso de análisis y valoración. En este trabajo, se diseña un perceptrón multicapa para una de las tipologías de activos más numerosas: las viviendas. Para ello, se analizan un total de 200 viviendas diferentes, que se utilizan para el entrenamiento y validación del modelo. Los resultados permiten predecir, con un grado de ajuste elevado, el importe estimado de los trabajos de adecuación de habitabilidad.

**Palabras clave:** *red neuronal artificial; perceptrón multicapa; activo inmobiliario; vivienda*

Correspondencia: David Bienvenido-Huertas, jbienvenido@us.es



©2018 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

## 1. Introducción

El inicio de la crisis financiera en el año 2008 cambió de manera significativa la economía en España. Antes de la crisis, el mercado inmobiliario español constituía la principal fuente de inversión al presentar un acelerado crecimiento en los años comprendidos entre 1990 y 2006. En este período, las entidades financieras jugaron un papel fundamental al financiar la adquisición de viviendas a los ciudadanos y la ejecución de las obras a los promotores.

Sin embargo, desde el año 2008 la gran actividad generada por dichas entidades ha provocado que haya aumentado en más de 600.000 el número de las ejecuciones hipotecarias debido a incumplimientos en las condiciones contractuales de los préstamos (Crump et al., 2008; Gutiérrez & Vives, 2018). Así pues, una de las consecuencias de esta situación es el incremento en el número de una amplia variedad de activos inmobiliarios en propiedad por parte de las entidades bancarias, situación que provoca que estas sean las mayores empresas inmobiliarias en la actualidad (Cruz Valdivieso, 2015). En este sentido, en los últimos años dichas entidades han creado empresas especializadas y destinadas a la gestión de los activos inmobiliarios, o han trasladado sus activos a la Sociedad de Gestión de Activos procedentes de la Reestructuración Bancaria (Fernández Muñoz & Collado Cueto, 2017). El objetivo fundamental de estas nuevas empresas es disminuir el riesgo asociado a los activos mediante la maximización de su valoración económica para su puesta en el mercado (Byrne, 2015). Así pues, se trata de un medio fundamental que disponen las entidades bancarias para su adecuada recuperación económica. De esta manera, la gestión de los activos inmobiliarios constituye, en la actualidad, una de las principales actividades en el sector de la edificación.

No obstante, para una adecuada gestión se debe consumir una gran cantidad de recursos temporales. El personal técnico de estas empresas debe trasladarse al activo a analizar, realizar una inspección pormenorizada de los desperfectos que presenta y emitir un informe. Uno de los aspectos más significativos de este proceso es la valoración económica de las actuaciones necesarias, ya que suele conllevar un tiempo considerable a los técnicos e incide en la decisión por parte de la entidad financiera de la idoneidad de realizar los trabajos. Por tanto, disponer de técnicas que agilicen este proceso de trabajo facilitará la labor de los técnicos y permitirá una mayor rapidez en la puesta en valor del stock inmobiliario existente.

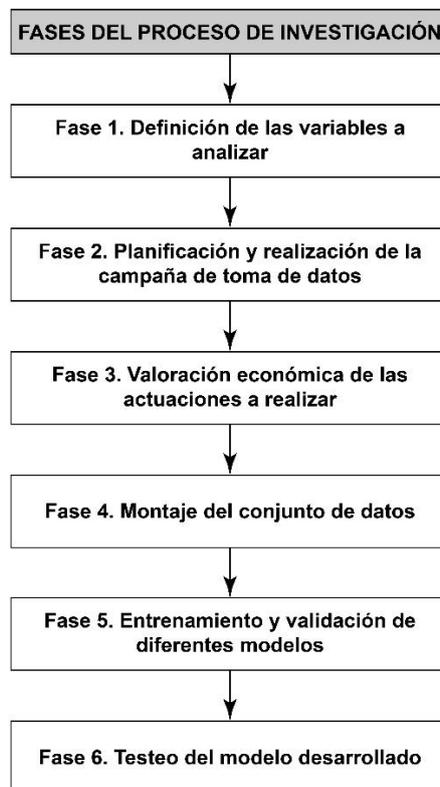
De acuerdo con esto, una de las formas más utilizadas para optimizar el proceso de organización de trabajos y reducir el tiempo asociado a los diferentes procesos es mediante la utilización de la inteligencia artificial (Quintas, Lefrere, & Jones, 1997). De los diferentes algoritmos existentes, las redes neuronales artificiales son de las que mejores prestaciones ofrecen con respecto a otras técnicas estadísticas como la regresión lineal (Kim, An, & Kang, 2004). En consecuencia, en los últimos años se ha incrementado el uso de modelos de redes neuronales artificiales para diferentes usos tales como la valoración económica de viviendas (Abidoye & Chan, 2018) o la estimación de costes de ejecución asociados a alguna fase de ejecución concreta (Hola & Schabowicz, 2010; Milion, Paliari, & Liboni, 2016), aunque no existen investigaciones referentes a la viabilidad de utilizarlas para predecir el importe económico asociado a las actuaciones de adecuación de habitabilidad en los activos inmobiliarios.

## 2. Objetivos

El objetivo fundamental de la investigación es desarrollar un modelo de predicción mediante una red neuronal artificial que permita estimar con exactitud el importe asociado a las actuaciones de adecuación de habitabilidad de una de las tipologías de activos inmobiliarios más abundantes: las viviendas. Para ello, la investigación se dividió en una serie de fases de trabajo (ver figura 1) en la que se recopilaron 200 casos de estudio para el entrenamiento y

validación del modelo de predicción, y así determinar la configuración más adecuada y el grado de ajuste de la estimación predicha.

**Figura 1: Fases del proceso de investigación realizado**



### 3. Metodología

#### 3.1. Diseño del modelo de predicción

En este trabajo se utiliza como tipología de red neuronal artificial el perceptrón multicapa (PM). Esta clase de red neuronal artificial se caracteriza por dividir su estructura en tres o más capas, que son las siguientes:

- Una capa de entrada que recibe la información de las variables de entrada.
- Una o varias capas intermedias que extraen la información requerida.
- Una capa de salida que indica el valor predicho por el modelo.

En cada una de ellas existen una serie de nodos o neuronas que se conectan a todos los de la siguiente capa mediante conexiones ponderadas con pesos sinápticos. El ajuste de los pesos sinápticos se realiza mediante el entrenamiento del PM que consiste en aplicar un algoritmo de aprendizaje a un conjunto de datos de entrenamiento. En el caso de este trabajo, los modelos de PM se entrenaron mediante el algoritmo BFGS (Fletcher, 1980). Los entrenamientos se realizaron mediante validación cruzada de 10 iteraciones y se utilizó una función de activación sigmoide para los nodos de sus diferentes capas.

A efectos de este estudio, únicamente se consideró una arquitectura de PM con una capa oculta. El número de neuronas de dicha capa y el tiempo de entrenamiento variaron en la etapa de diseño hasta determinar el modelo de PM más adecuado. En el apartado de resultados se analiza el número de neuronas para la capa oculta con un mejor

comportamiento. Para poder determinar cuál es el mejor modelo obtenido, se utilizaron tres parámetros estadísticos:

- El coeficiente de correlación ( $R^2$ ) (Ec. (1)).
- El error medio absoluto (MAE) (Ec. (2)).
- La desviación de la raíz cuadrada media (RMSE) (Ec. (3)).

$$R^2 = \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n x_i^2} \quad (1)$$

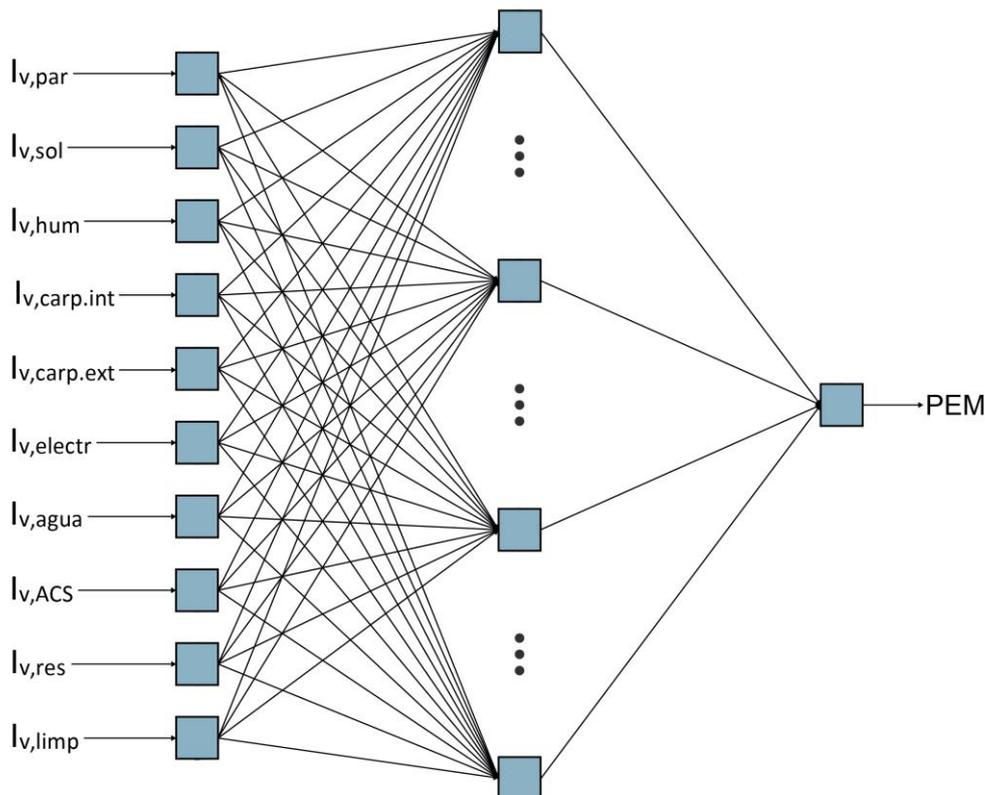
$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (2)$$

$$RMSE = \left( \frac{\sum_{i=1}^n (y_i - x_i)^2}{n} \right)^{1/2} \quad (3)$$

Donde  $n$  es el número de instancias en el conjunto de datos de entrenamiento,  $x_i$  es la valoración económica real y  $y_i$  es la valoración predicha por el modelo.

Se estableció como indicador de calidad del modelo que  $R^2$  debía tener un valor superior a 95% y que tanto MAE como RMSE debían ser lo más bajo posible. Para el diseño del PM se tuvieron en cuenta los principales factores que influyen en la valoración económica de las actuaciones de adecuación de habitabilidad, constituyendo las variables de entrada del modelo (ver figura 2). La respuesta de salida corresponde con el presupuesto de ejecución material (PEM) de los trabajos.

**Figura 2: Esquema del PM planteado**



En la tabla 1 se indican los factores que se tuvieron en cuenta en la determinación del estado

del activo inmobiliario. Asimismo, en dicha tabla se realiza una descripción de cada una de estas variables.

**Tabla 1: Variables de entrada en el PM diseñado**

Código	Nombre	Descripción
I <sub>v,par</sub>	Índice de estado de paramentos	Estado de los paramentos, en el que se incluyen aspectos como su correcta verticalidad, la existencia de desperfectos o la calidad del acabado. En los valores asociados se incluyen aspectos como el tapado de agujeros, la renovación del acabado e incluso su demolición y reconstrucción.
I <sub>v,sol</sub>	Índice de estado de solerías	Estado de las solerías en función de la presencia de piezas sueltas o rotas o la carencia de estas. En los valores asociados a este índice se incluyen la recolocación de las piezas sueltas y su disposición en las superficies que carecen de ellas.
I <sub>v,hum</sub>	Índice de patologías de humedad	Existencia de patologías debidas a humedades de diferentes tipos (condensación, capilaridad o filtración). En los valores asociados a este índice se incluyen la eliminación del origen de la humedad, así como el saneado del elemento dañado.
I <sub>v,carp.int</sub>	Índice de estado de carpintería interior	Estado de la carpintería interior de la vivienda (puertas, cerrajería y otros elementos). En los valores asociados a este índice se incluyen la reparación de los desperfectos de la carpintería y cerrajería, e incluso la retirada y colocación de elementos nuevos.
I <sub>v,carp.ext</sub>	Índice de estado de carpintería exterior	Estado de la carpintería exterior de la vivienda (ventanas, balconeras y elementos de protección). En los valores asociados a este índice se incluyen la reparación de los desperfectos de la carpintería, así como la retirada y colocación de elementos nuevos.
I <sub>v,agua</sub>	Índice de estado de instalación de agua	Estado de la instalación de suministro y evacuación de agua de la vivienda. En los valores asociados a este índice se incluyen la disposición de elementos faltantes o en mal estado, la reparación de averías y la renovación parcial o total de la instalación de agua de la vivienda.
I <sub>v,electr</sub>	Índice de estado de instalación eléctrica	Estado de la instalación eléctrica de la vivienda. En los valores asociados a este índice se incluyen la colocación de elementos faltantes o en mal estado, la reparación de averías y la renovación parcial o total de la instalación eléctrica de la vivienda.
I <sub>v,ACS</sub>	Índice de estado de sistema de ACS	Estado del sistema de agua caliente sanitaria (ACS), en el que se analiza su correcto funcionamiento. En los valores asociados a este índice se incluyen la colocación de elementos faltantes o en mal estado, así como la reparación de averías y la renovación parcial o total del sistema de ACS.
I <sub>v,res</sub>	Índice de existencia de residuos	Existencia de residuos en la vivienda que suponen un peligro para la seguridad y salud de las personas. En los valores asociados a este índice se incluyen los trabajos de retirada, gestión y traslado a vertedero de los residuos existentes.
I <sub>v,limp</sub>	Índice de nivel de limpieza	Estado del nivel de limpieza de la vivienda en función de la presencia de residuos, así como la existencia de parásitos que supongan un peligro para la salud de las personas. En los valores asociados a este índice se incluyen tareas como la limpieza de la vivienda y la aplicación de productos fumigantes.

Es conveniente destacar que los valores discretos normalmente utilizados en estas actuaciones para valorar el estado del inmueble se transforman en una escala de 0 a 1 correspondiendo a las diferentes variables de entrada. Esta transformación se realiza con el fin de mejorar el proceso de entrenamiento del PM y agilizar la toma de datos en las

inspecciones al establecer un valor dentro de una escala numérica. Los valores se establecen de menor a mayor gravedad, siendo los extremos de la distribución de los valores para cuando el estado sea correcto (0) y para cuando sea urgente la actuación (1). En los valores asociados a cada uno de estos índices se incluyen también los trabajos relacionados con la gestión y el traslado a vertedero de los residuos generados.

El valor estimado por el PM determina el PEM asociado a las actuaciones de adecuación de habitabilidad. Para cada uno de los casos de estudio incluidos en el conjunto de datos de entrenamiento, se determinó dicho importe utilizando el modelo de presupuesto de unidades de obra (Ramírez de Arellano, 2010). En dicho modelo, las actuaciones a ejecutar se dividen en una serie de unidades o tareas a las que se les asocia un importe obtenido al aplicar una medición o cantidad a un precio asignado. El importe total de la ejecución de las obras de adecuación de habitabilidad se obtiene mediante la suma de los costes directos, obtenidos a través del sumatorio del importe económico de todas las unidades (Ec. (4)), y de los costes indirectos (Ec. (5)). Los precios se obtuvieron a través de la Base de Datos de Precios publicada por el Gabinete Técnico del Colegio Oficial de Aparejadores, Arquitectos Técnicos e Ingenieros de Edificación de Guadalajara (COAATGU, 2017).

$$CD = \sum_{i=1}^n U_i \quad (4)$$

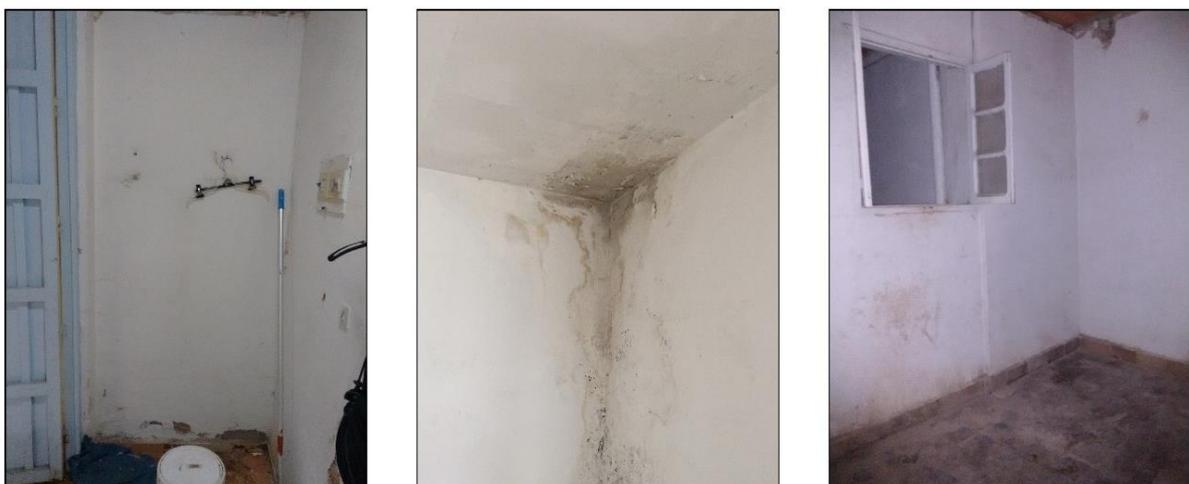
$$PEM = CD + CI \quad (5)$$

Donde  $U_i$  es una unidad de obra, CD es el importe de costes directos y CI es el importe de los costes indirectos.

### 3.2. Generación del conjunto de datos

Para poder desarrollar una red neuronal artificial resulta necesario disponer de un conjunto de datos robusto que se utilice para entrenar y validar el sistema. Para ello, se recopilieron 200 casos de estudio diferentes ubicados en la provincia de Sevilla (ver figura 3). En cada uno de ellos se analizaron las diferentes variables de entrada indicadas en la tabla 1, se determinaron las actuaciones necesarias, así como el presupuesto de ejecución material para dichos trabajos.

**Figura 3: Fotografías de varios aspectos analizados del interior de tres viviendas diferentes incluidas en el conjunto de datos desarrollado**



Para el entrenamiento y validación del PM, se utilizaron 193 casos de estudio. Los otros 7

casos de estudio se utilizaron para testear el modelo generado y ver su comportamiento ante nuevos activos inmobiliarios no incluidos en el proceso de entrenamiento.

#### 4. Resultados y discusión

En una primera fase se estudió la arquitectura de PM con un comportamiento más eficiente. Tal y como se ha indicado anteriormente, el modelo de PM más adecuado se determinó mediante los parámetros estadísticos de  $R^2$ , MAE y RMSE. En esta fase se estudiaron las arquitecturas de modelos con un número de neuronas en la capa oculta que osciló entre 5 y 16 (ver tabla 2).

**Tabla 2: Comportamiento de los parámetros estadísticos de las arquitecturas de PM**

Arquitectura de PM	Número de neuronas en capa oculta	$R^2$	MAE	RMSE
PM-5	5	94,62	260,36	627,47
PM-6	6	96,55	242,95	469,42
PM-7	7	96,65	233,31	461,57
PM-8	8	96,56	254,85	580,55
PM-9	9	96,25	243,72	489,87
PM-10	10	96,67	236,05	460,67
PM-11	11	96,90	225,77	448,38
PM-12	12	96,90	221,25	447,05
PM-13	13	96,37	235,66	491,89
PM-14	14	96,57	225,24	475,32
PM-15	15	96,07	247,46	510,76
PM-16	16	97,02	222,12	476,19

Para todas las configuraciones planteadas, el coeficiente de correlación presentado por los diferentes modelos estuvo por encima del 94,50%, presentando en la gran mayoría de ellos valores superiores al 96%, por lo que está dentro del porcentaje adecuado indicado anteriormente (95%).

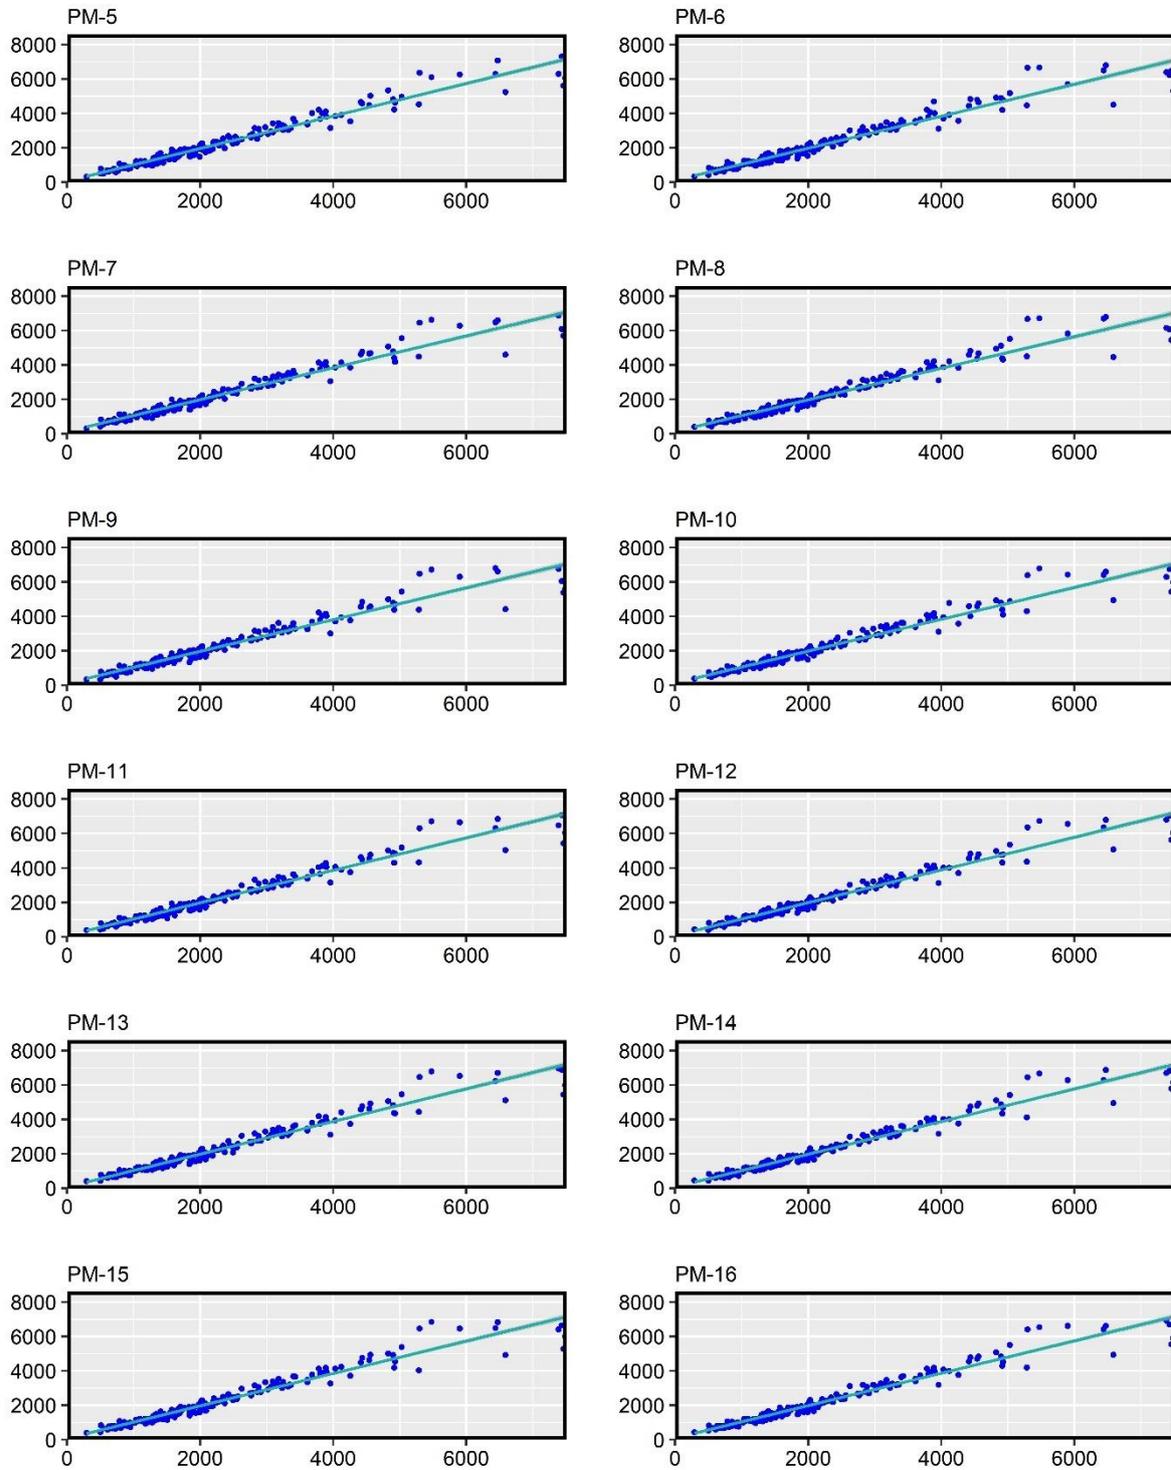
De acuerdo con lo indicado, se puede apreciar cómo las nubes de puntos de las diferentes arquitecturas presentan un comportamiento similar, por lo que no es posible determinar una configuración más adecuada que otra con base en la linealidad entre las variables de respuesta y estimada (ver figura 4).

A pesar de que el porcentaje de correlación obtenido para los diferentes modelos fue adecuado, en los parámetros de error se obtuvo una gran variedad de resultados, los cuales sirvieron para la determinación de la arquitectura más adecuada.

En este sentido, el modelo que presentó valores menores de MAE y de RMSE fue el más adecuado. De acuerdo con esto, el modelo más adecuado fue el de 12 nodos en la capa oculta (PM-12) al presentar un MAE de 221,25 y un RMSE de 447,05, con desviaciones con respecto al siguiente modelo con valores más bajos (PM-16) de 0,39% y de 6,12%, respectivamente. Además, PM-12 tuvo el segundo coeficiente de correlación más elevado (96,90%) de las diferentes arquitecturas estudiadas, con una desviación de -0,12% con

respecto al valor más elevado registrado (PM-16).

**Figura 4: Comparación de la correlación existente entre los valores obtenidos por PM para las diferentes arquitecturas planteadas. En el eje de abscisas se representa el valor real presupuestado y en el eje de ordenadas el valor estimado.**



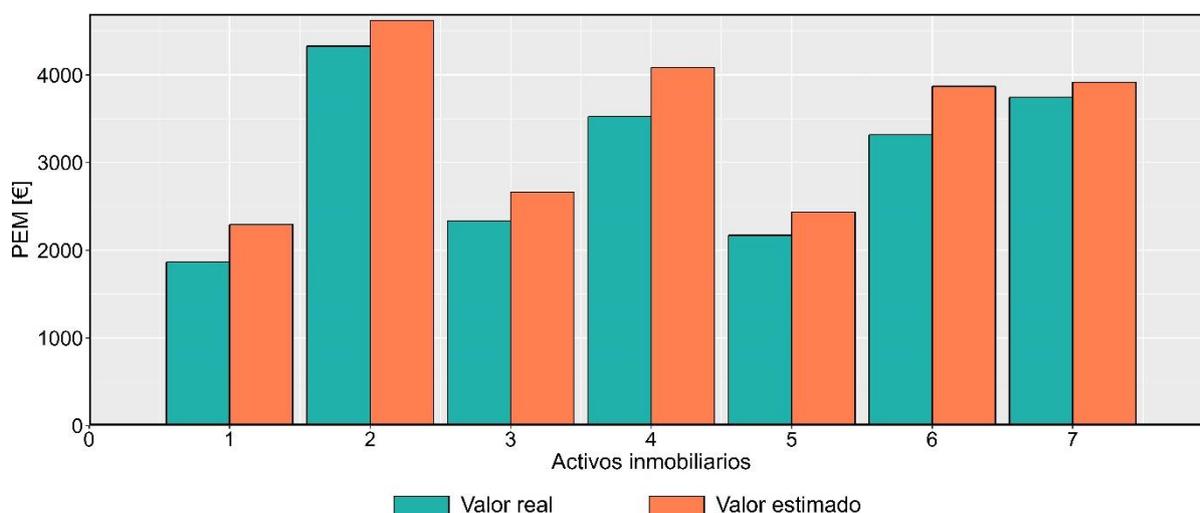
Finalmente, se utilizaron 7 nuevos casos de estudio para estudiar el grado de ajuste y el error

de las predicciones económicas ante ejemplos nuevos. Los parámetros estadísticos del comportamiento del modelo para estos nuevos casos de estudio se encuentran en la tabla 3, y en la figura 5 se representan de manera gráfica las diferencias existentes entre los valores reales y estimados para cada instancia testeada.

**Tabla 3: Parámetros estadísticos de los resultados obtenidos en la fase de testeo**

R <sup>2</sup>	MAE	RMSE
98.74	370.294	394.39

**Figura 5: Diagrama de barras con los valores reales y estimados para los datos nuevos utilizados en el testeo del modelo**



Tal y como se puede apreciar, la correlación obtenida en esta fase presentó un grado de ajuste superior al 98%, a pesar de que existieron algunas diferencias entre los valores reales y estimados del PEM que resulta conveniente destacar. En este sentido, se obtuvo un porcentaje de desviación máximo de 22,82% en uno de los casos de estudio, aunque en la gran mayoría de ellos se consiguieron porcentajes inferiores al 16%. Por otro lado, los parámetros estadísticos de error presentaron un comportamiento diferente con desviaciones con respecto al modelo PM-12 de 67,36% para MAE y de -11,78 para RMSE.

A pesar de estas desviaciones, los resultados predichos por el PM fueron cercanos a los valores reales y se puede garantizar la robustez del modelo ante nuevos casos de estudio. Así pues, el PM planteado se puede utilizar para determinar, con un grado de ajuste elevado, la valoración económica de las actuaciones de adecuación de habitabilidad de los activos inmobiliarios y, de esta manera, determinar el grado de inmediatez en dichos trabajos por parte de las entidades financieras. En cualquier caso, en futuras investigaciones se deberá utilizar una muestra de estudio mayor para obtener un mejor comportamiento del modelo.

## 5. Conclusiones

Tras el estudio realizado, se ha obtenido un modelo de red neuronal artificial para realizar la estimación económica de las actuaciones de adecuación de habitabilidad en viviendas, ya que constituyen una de las tipologías de activos inmobiliarios de mayor número. Para ello, se utilizó el perceptrón multicapa como clase de red neuronal artificial, utilizando como muestra de entrenamiento un conjunto de datos compuesto por 193 casos de estudio. El entrenamiento

se realizó mediante el algoritmo BFGS y se utilizó una validación cruzada de 10 iteraciones.

Los resultados ponen de manifiesto que la arquitectura que presentó un comportamiento más adecuado fue la de 12 neuronas en la capa oculta, ya que se obtuvo un coeficiente de correlación adecuado (96,90%) y unos parámetros de error menores con respecto a las otras configuraciones estudiadas. Posteriormente, dicho modelo fue utilizado ante 7 nuevos casos de estudio para testear su comportamiento ante nuevas instancias, obteniendo resultados ajustados con una desviación inferior al 16% para la mayoría de los casos nuevos. Así pues, el modelo desarrollado presenta un comportamiento adecuado para predecir el presupuesto de ejecución material de los trabajos de adecuación.

Próximas fases de esta investigación irán orientadas a obtener una muestra mayor de actuaciones de viviendas, así como la generación de nuevos modelos para otras tipologías de activos como los solares.

## 6. Referencias

- Abidoys, R. B., & Chan, A. P. C. (2018). Improving property valuation accuracy: a comparison of hedonic pricing model and artificial neural network. *Pacific Rim Property Research Journal*, 5921, 1–13. <https://doi.org/10.1080/14445921.2018.1436306>
- Byrne, M. (2015). Bad banks: the urban implications of asset management companies. *Urban Research and Practice*, 8(2), 255–266. <https://doi.org/10.1080/17535069.2015.1050208>
- COAATGU. (2017). Base Construction Costs of Spain Centre. Retrieved February 3, 2017, from <http://preciocentro.com/>
- Crump, J., Newman, K., Belsky, E. S., Ashton, P., Kaplan, D. H., Hammel, D. J., & Wyly, E. (2008). Cities Destroyed (Again) For Cash: Forum on the U.S. Foreclosure Crisis. *Urban Geography*, 29(8), 745–784. <https://doi.org/10.2747/0272-3638.29.8.745>
- Cruz Valdivieso, A. M. (2015). *Definición de un Modelo de Gestión para los Activos Inmobiliarios mediante Procesos Estructurados*. University of Alicante.
- Fernández Muñoz, S., & Collado Cueto, L. (2017). What has happened in Spain? The real estate bubble, corruption and housing development: A view from the local level. *Geoforum*, 85(March 2015), 206–213. <https://doi.org/10.1016/j.geoforum.2017.08.002>
- Fletcher, R. (1980). *Practical methods of optimization*. Chichester - New York - Brisbane - Toronto, United States: John Wiley&Sons.
- Gutiérrez, A., & Vives, S. (2018). Acumulación de viviendas por parte de los bancos a través de los desahucios: geografía de la desposesión de vivienda en Cataluña. *Eure*, 44(132), 5–26.
- Hola, B., & Schabowicz, K. (2010). Estimation of earthworks execution time cost by means of artificial neural networks. *Automation in Construction*, 19(5), 570–579. <https://doi.org/10.1016/j.autcon.2010.02.004>
- Kim, G. H., An, S. H., & Kang, K. I. (2004). Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning. *Building and Environment*, 39(10), 1235–1242. <https://doi.org/10.1016/j.buildenv.2004.02.013>
- Milion, R. N., Paliari, J. C., & Liboni, L. H. B. (2016). Improving consumption estimation of electrical materials in residential building construction. *Automation in Construction*, 72, 93–101. <https://doi.org/10.1016/j.autcon.2016.08.042>
- Quintas, P., Lefrere, P., & Jones, G. (1997). Knowledge Management: a Strategic Agenda.

*Long Range Planning*, 30(3), 385–391. [https://doi.org/10.1016/S0024-6301\(97\)90252-1](https://doi.org/10.1016/S0024-6301(97)90252-1)

Ramírez de Arellano, A. (2010). *Presupuestación de obras*. Seville, Spain: University of Seville.