

# AUNANDO LOS ENSAYOS DE CARACTERIZACIÓN DE LA TRANSMITANCIA TÉRMICA DE FACHADAS EN EDIFICIOS CON LA CARACTERIZACIÓN ACÚSTICA MEDIANTE INTELIGENCIA ARTIFICIAL

David Bienvenido-Huertas<sup>1</sup>

<sup>1</sup> Universidad de Sevilla, Departamento de Construcciones Arquitectónicas II  
{e-mail: [jbienvenido@us.es](mailto:jbienvenido@us.es)}

## Resumen

El contexto actual de cambio climático está obligando a mejorar la eficiencia energética de los edificios. Para ello, ensayos de auditoría energética, como los ensayos de caracterización de la transmitancia térmica de las fachadas de los edificios, están cobrando mayor importancia. Estos ensayos consisten en la medición de variables tales como las temperaturas ambientales, superficiales y flujo de calor. Estudios anteriores han mostrado como la aplicación de la inteligencia artificial puede caracterizar variables térmicas físicas. A raíz de estos resultados, en este estudio se plantea la posibilidad de caracterizar el índice de reducción sonora global del cerramiento analizado con los ensayos de transmitancia térmica. Para ello, se utilizó un conjunto de datos de 22.820 observaciones y se analizaron con bosques aleatorios. Los resultados permitieron realizar estimaciones adecuadas con un error promedio bajo del índice global de reducción acústica ponderado A. Estos resultados permitirían abrir la posibilidad de combinación de las caracterizaciones térmicas de los ensayos de auditoría energética con la caracterización acústica de los edificios.

**Palabras clave:** auditoría energética, ensayos de transmitancia térmica, índice de reducción sonora global, inteligencia artificial, edificios.

## Abstract

The current context of climate change is leading to an improvement of building energy efficiency. For this purpose, energy audit tests, such as tests to characterize the thermal transmittance of building façades, are becoming more important. These tests consist of the measurement of variables, for example, ambient and surface temperatures and the heat flow. Previous studies have shown how the application of artificial intelligence can characterize physical thermal variables. As a result, this study presents the possibility of characterizing the weighted sound reduction index of the enclosure analyzed with thermal transmittance tests. A dataset of 22,820 observations was used and analyzed with artificial neural networks. The results obtained adequate estimates whose average error of the weighted sound reduction index was low. Finally, this study would raise the possibility of combining the thermal characterizations of energy audit tests with the acoustic characterization of buildings.

**Keywords:** energy audit, thermal transmittance tests, weighted sound reduction index, artificial intelligence, buildings.

**PACS no.** 43.55.Ti

## 1 Introducción

La disminución del consumo energético de los edificios constituye uno de los principales retos de la sociedad actual. En el caso de la Unión Europea, su hoja de ruta hacia una economía hipocarbónica establece el objetivo de reducir en un 90% las emisiones a la atmósfera con respecto a los niveles de 1990 [1]. Por lo tanto, la reducción del consumo energético de los edificios resulta fundamental para alcanzar dicho objetivo. La mayor parte de este consumo es debido a la utilización de los sistemas de climatización [2,3]. En este sentido, resulta fundamental conocer el rendimiento térmico de la envolvente del edificio para poder conocer con exactitud la demanda energética del mismo y poder establecer medidas de ahorro energético [4,5]. En los últimos años se han desarrollado numerosas investigaciones en el campo de la caracterización térmica de la envolvente. La mayoría de estos estudios están orientados a la caracterización experimental de la transmitancia térmica de la envolvente [6].

La caracterización experimental de la transmitancia térmica de cerramientos puede ser realizada por diferentes procedimientos. Los dos más utilizados son el método termoflujométrico (HFM) y el método termométrico (THM) (ver Figura 1). HFM viene desarrollado en la ISO 9869-1 [6] y consiste en la medición de la fachada del flujo de calor y de la temperatura del aire interior y exterior durante períodos de tiempo que van desde los 3 hasta los 7 días. Algunos estudios han reflejado limitaciones y requisitos que deben ser tenidos en cuenta a la hora de monitorizar las fachadas con el método. Por ejemplo, Cesaratto et al. [7], Desogus et al. [8] and Trethowen [9] detectaron como una de las principales contribuciones de error en el método era debida a la medición del flujo de calor. En este sentido, Meng et al. [10] establecieron que el error asociado a la colocación del termoflujómetro puede llegar a alcanzar un 26%. Además, la necesidad de garantizar un gradiente térmico elevado [8,11], la orientación del cerramiento [12] y la presencia de condensaciones [13] o congelaciones [14] ha sido reportado por varios estudios para poder garantizar la representatividad de los resultados [8,11].




Figure 1 – Esquemas del heat Flow meter method and the thermometric method.

Una variación del HFM se encuentra en el THM. El THM se trata de un método que sustituye la medición del flujo de calor por la de la temperatura superficial [15,16]. Esto es debido a las fuentes de error asociadas por el flujo de calor en la determinación de la transmitancia térmica que han sido

reflejados en algunos estudios [9,10]. Su fundamento teórico se basa en la ley del enfriamiento de Newton y considera que la transferencia de calor por conducción es equivalente a la transferencia de calor por radiación y convección en estado estacionario. Tanto HFM como THM tiene una amplia utilización a nivel científico y profesional [6]. Sin embargo, las características de los métodos pueden presentar limitaciones que pueden dificultar su correcta utilización. En este sentido, una de las limitaciones asociadas es la validación de los resultados experimentales. Para ello, la ISO 9869-1 recoge que la validación de los resultados experimentales se realizará a través del análisis de la desviación porcentual entre el valor obtenido en los resultados y el valor teórico obtenido a través de la ISO 6946 [17]. La limitación de este aspecto es que la ISO 6946 requiere de un conocimiento previo de las capas y propiedades térmicas de la fachada, por lo que su utilización en edificios existentes presenta muchas limitaciones [18]. Ante esta circunstancia, un estudio reciente planteó la posibilidad de caracterizar la transmitancia térmica de la ISO 6946 a través de técnicas estadísticas basadas en la inteligencia artificial (IA) y con los datos obtenidos del proceso de monitorización [19]. El objetivo era poder utilizar los modelos de IA para determinar el valor teórico que tiene el cerramiento, sin necesidad de conocer su composición y propiedades, y poder validar los resultados experimentales. Los modelos de IA desarrollados permitieron realizar estimaciones con un coeficiente de determinación superior al 99,55% y con un error promedio inferior a 0,05 W/(m<sup>2</sup>K). En base a esos resultados, en un estudio posterior, Bienvenido-Huertas et al. [20] analizaron la posibilidad de predecir con éxito mediante modelos de IA las propiedades térmicas periódicas de la fachada, tales como la transmitancia térmica periódica o la admitancia térmica.

Sin embargo, ningún estudio previo ha evaluado la posibilidad de realizar caracterización de propiedades térmicas acústicas a través de los datos obtenidos de los procesos de monitorización de transmitancia térmica. Por este motivo, este estudio plantea la posibilidad de realizar caracterizaciones del índice global de reducción acústica ponderado A ( $R_A$ ) de la fachada a través de los datos monitorizados con el HFM o con el THM. Para ello, se parte de la formulación matemática de aproximación recogida en el Código Técnico de la Edificación y utilizando un conjunto de datos compuesto por 22.820 ensayos simulados en fachadas (obtenidos de la combinación de 163 monitorizaciones reales con 140 diseños de fachadas) se realizaron estimaciones adecuadas de  $R_A$ .

## **2 Metodología**

### **2.1 Generación del conjunto de datos**

Uno de los requisitos fundamentales para la correcta aplicación de los planteamientos de modelos predictivos con IA es disponer de un gran conjunto de datos que garantice el correcto aprendizaje de los modelos. Dado que el esfuerzo temporal que puede suponer la realización de una muestra amplia de ensayos puede limitar la utilización de un planteamiento de estas características, se diseñaron simulaciones transitorias bidimensionales para la generación de los conjuntos de datos necesarios. Estas simulaciones se hicieron con el software HTFlux.

Las simulaciones se basaron en una combinación de ensayos reales con modelos de fachada simulados (Figura 2). Para ello, se modelaron 140 tipologías diferentes de fachadas. El diseño de estas tipologías se basó tanto en los cerramientos incluidos en el Catálogo de Elementos Constructivos (Instituto de Ciencias de la Construcción Eduardo Torroja, 2010) como en los procedentes de diversos estudios de catalogación de las fachadas del parque inmobiliario español [22,23]. Por lo tanto, los modelos diseñados corresponden a tipologías de fachadas de los períodos constructivos característicos del parque inmobiliario español. En el caso de los cerramientos construidos en los períodos constructivos

posteriores a la NBE-CT-79, los materiales aislantes fueron varios, entre los que destacan el poliestireno expandido, la lana mineral, el poliuretano y el poliestireno extruido. El hecho de que los muros fueran diseñados en el proceso de simulación permitió que se dispusiera de un conocimiento exacto de sus capas (es decir, del tipo de material, de espesor y de las propiedades térmicas de cada capa). Por consiguiente, se pudo disponer de un conjunto de datos con conocimientos precisos de  $R_A$ . Para la determinación de  $R_A$  se utilizaron las dos expresiones de aproximación recogidas en el Código Técnico de la Edificación:

$$R_A = 16,6 \log(m) + 5 \quad \text{si } m \leq 150 \text{ kg/m}^2 \quad (1)$$

$$R_A = 36,5 \log(m) - 38,5 \quad \text{si } m > 150 \text{ kg/m}^2 \quad (2)$$

Cada una de estas 140 tipologías de fachadas se combinó con un conjunto de 163 series de tiempo de temperatura de aire interior y exterior que se obtuvieron en la campaña 1. Por lo tanto, se consiguió un total de 22.820 combinaciones diferentes entre las tipologías de muros y las series de tiempo. Estas mediciones se llevaron a cabo en diversas condiciones de ensayo. Así pues, existieron monitorizaciones tanto en condiciones favorables como desfavorables, lo cual permitió abarcar una amplia variedad de condiciones de ensayo.

En cada una de estas 22.820 combinaciones se realizaron simulaciones transitorias bidimensionales para obtener las variables de temperatura superficial y de flujo de calor. Como condiciones de contorno, se usaron las resistencias térmicas superficiales establecidas en la ISO 6946:2007 para flujos horizontales de calor: 0,13 m<sup>2</sup>K/W para condiciones internas y 0,04 m<sup>2</sup>K/W para condiciones externas. Esto se debió al hecho de que la ISO 6946:2007 recomienda estos valores de resistencia térmica superficial para las envolventes de edificios típicos y ante condiciones normales de funcionamiento (es decir, con una temperatura interior dentro de unos rangos aceptables de confort térmico). Asimismo, conviene destacar que estos valores de resistencia térmica superficial se han utilizado en otros estudios de investigación similares sobre caracterización térmica a través de simulaciones transitorias [19].




Figura 2 – Flujo de trabajo del proceso de simulación realizado en la investigación.

Asimismo, la duración de las monitorizaciones de la campaña 1 osciló entre 3 y 7 días. Por lo tanto, la duración que correspondiera a cada serie de tiempo se consideró como tiempo de simulación. Otros aspectos concernientes al proceso de simulación tuvieron que ver con el tiempo de adquisición de datos y con la localización de la sonda de la temperatura superficial y del flujo de calor. Por una parte, se aplicaron intervalos de 15 minutos, los cuales coinciden con los empleados en la medición de las temperaturas de aire interior y exterior. Por otra parte, las variables medidas se localizaron a una altura de 1,50 m del suelo para evitar efectos bidimensionales en el flujo de calor por la unión con el forjado. Este criterio va en consonancia con los criterios operativos recogidos en las investigaciones existentes de los métodos de transmitancia térmica.

Asimismo, se disponía de las mediciones de las variables de temperatura superficial y de flujo de calor de 163 ensayos reales, las cuales se utilizaron para validar los datos simulados y, de esta manera, garantizar la representatividad de los datos usados. Al finalizar el proceso de simulación, se dispuso de un total de 22.820 ensayos diferentes. En la Figura 3 se representan varios ejemplos de los datos obtenidos. A su vez, el uso de estos ensayos en los distintos modelos de IA varió en función de las necesidades del estudio. El 75% de los 22.820 ensayos se utilizaron para conformar el conjunto de datos de entrenamiento (con 17.115 instancias), y el 25% restante para el conjunto de datos de testeo (con 5.705 instancias).

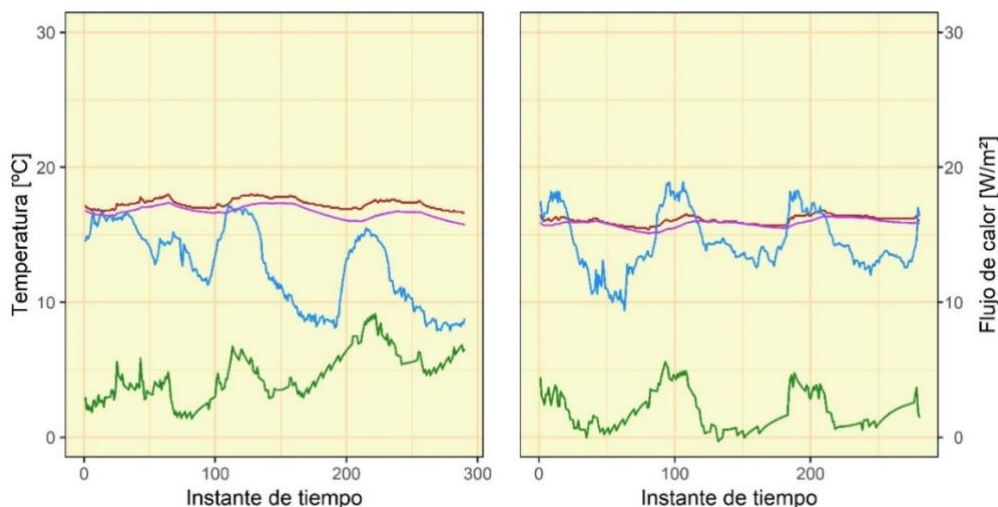


Figura 3 – Ejemplo de varias series de tiempo simuladas. En los gráficos se representa la temperatura del aire interior (en color rojo), la temperatura del aire exterior (en color azul), la temperatura superficial interior (en color lila) y el flujo de calor (en color verde).

## 2.2 Algoritmo de IA: bosque aleatorio

El algoritmo de IA utilizado fue el bosque aleatorio (BA). BA es una evolución de los árboles de clasificación y de regresión. BA funciona creando un conjunto de modelos de árboles de clasificación y de regresión eliminando algunas de las limitaciones que pueden presentar los modelos de árbol como puede ser el sobreajuste o la influencia de valores atípicos [24,25] y reduce la varianza y el sesgo del modelo [26,27]. Asimismo, se trata de un algoritmo que permite desarrollar modelos eficientes ante grandes conjuntos de datos y que no se ve influenciado por valores atípicos [28]. El número de árboles considerados en el algoritmo tiene una influencia significativa en el rendimiento del modelo de BA [29]. Para el entrenamiento de un modelo de BA, se divide el subconjunto de entrenamiento en  $N$  muestras [27]. Cada muestra genera un modelo de árbol. La estimación dada por el modelo de BA ( $\hat{Y}_{BA}$ ) es obtenida del promedio de las estimaciones dada por cada árbol ( $\hat{Y}_t$ ):

$$\hat{Y}_{BA} = \frac{1}{T} \sum_{t=1}^T \hat{Y}_t \quad (3)$$

Donde  $T$  es el número de árboles.

## 3 Resultados y discusión

En primer lugar, fue necesario seleccionar el número óptimo de árboles de cada modelo de BA para optimizar su rendimiento. Para ello, se analizó el rendimiento obtenido por los modelos con números de árboles comprendidos entre 2 y 150. El rendimiento se analizó a través del coeficiente de determinación ( $R^2$ ) y del error promedio obtenido. El análisis mostró como modelos de BA con un número de 54 y de 56 con los datos de HFM y de THM fueron las opciones más adecuadas. En la Tabla 1 se resumen los resultados obtenidos por los parámetros estadísticos. Tal y como se puede apreciar, los rendimientos fueron satisfactorios en la fase de entrenamiento, aunque el rendimiento obtenido con el planteamiento HFM fue más adecuado. Pasando a analizar el error asociado a cada instancia del conjunto de datos de

testeo, en las Figuras 4 y 5 se incluyen los histogramas del error obtenido en el proceso de testeo. Tal y como se puede apreciar, el porcentaje de instancia con un error bajo fue elevado. En este sentido, en el planteamiento de HFM, el 69,79% de las instancias obtuvo un error inferior a 0,4 dBA, mientras que en el planteamiento de THM este porcentaje fue del 60,35%. Asimismo, hubo algunas limitaciones del planteamiento, ya que algunas instancias obtuvieron errores elevados. En cualquier caso, el bajo porcentaje de casos de las instancias destinadas al conjunto de datos de testeo (13,21% en HFM y 18,7% en THM) permite asegurar la fiabilidad del planteamiento para realizar caracterizaciones de RA a través de monitorizaciones de ensayos de transmitancia térmica.

Tabla 1 – Resultados obtenidos por los parámetros estadísticos en la fase de entrenamiento con la configuración óptima de árboles.

| Planteamiento | Numero de arboles | R2     | Error promedio |
|---------------|-------------------|--------|----------------|
| HFM           | 54                | 97,09% | 0,4469         |
| THM           | 56                | 95,70% | 0,6041         |

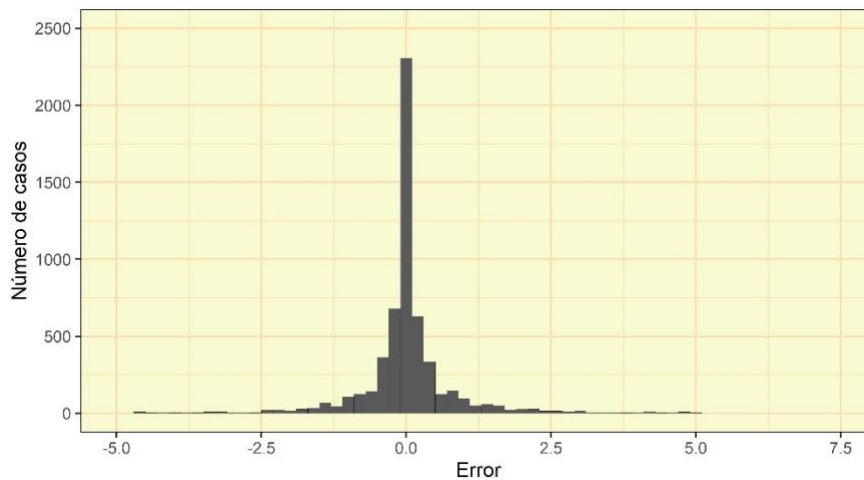


Figura 4 – Histograma del error obtenido en la estimación de RA con el modelo de bosque aleatorio del planteamiento HFM.




Figura 5 – Histograma del error obtenido en la estimación de RA con el modelo de bosque aleatorio del planteamiento THM.

## 4 Conclusiones

Los resultados de este estudio han mostrado la viabilidad de realizar caracterizaciones del índice global de reducción acústica ponderado A a través de monitorizaciones realizadas en los ensayos de caracterización de transmitancia térmica. Para ello, resulta fundamental disponer de modelos de predicción usando el algoritmo de bosques aleatorios. La ventaja de disponer de procedimientos de análisis combinado que permitan caracterizar diferentes variables o propiedades de la envolvente de edificios permitiría garantizar una mayor información del parque inmobiliario existente y garantizar una mayor rentabilidad en la realización de estos ensayos, al poder extraer más resultados.

## Referencias

- [1] European Commission. A Roadmap for moving to a competitive low carbon economy in 2050. Brussels, Belgium: 2011.
- [2] Kurekci NA. Determination of optimum insulation thickness for building walls by using heating and cooling degree-day values of all Turkey's provincial centers. *Energy Build* 2016;118:197–213. <https://doi.org/10.1016/j.enbuild.2016.03.004>.
- [3] Vine EL, Kazakevicius E. Residential energy use in Lithuania: The prospects for energy efficiency. *Energy* 1999;24:591–603. [https://doi.org/10.1016/S0360-5442\(99\)00013-4](https://doi.org/10.1016/S0360-5442(99)00013-4).
- [4] Invidiata A, Lavagna M, Ghisi E. Selecting design strategies using multi-criteria decision making to improve the sustainability of buildings. *Build Environ* 2018;139:58–68. <https://doi.org/10.1016/j.buildenv.2018.04.041>.
- [5] Rubio-Bellido C, Perez-Fargallo A, Pulido-Arcas JA. Optimization of annual energy demand in office buildings under the influence of climate change in Chile. *Energy* 2016;114:569–85. <https://doi.org/10.1016/j.energy.2016.08.021>.
- [6] Bienvenido-Huertas D, Moyano J, Marín D, Fresco-Contreras R. Review of in situ methods for assessing the thermal transmittance of walls. *Renew Sustain Energy Rev* 2019;102:356–71. <https://doi.org/10.1016/j.rser.2018.12.016>.
- [7] Cesaratto PG, De Carli M, Marinetti S. Effect of different parameters on the in situ thermal conductance evaluation. *Energy Build* 2011;43:1792–801. <https://doi.org/10.1016/j.enbuild.2011.03.021>.
- [8] Desogus G, Mura S, Ricciu R. Comparing different approaches to in situ measurement of building components thermal resistance. *Energy Build* 2011;43:2613–20. <https://doi.org/10.1016/j.enbuild.2011.05.025>.
- [9] Trethowen H. Measurement errors with surface-mounted heat flux sensors. *Build Environ* 1986;21:41–56. [https://doi.org/10.1016/0360-1323\(86\)90007-7](https://doi.org/10.1016/0360-1323(86)90007-7).
- [10] Meng X, Yan B, Gao Y, Wang J, Zhang W, Long E. Factors affecting the in situ measurement accuracy of the wall heat transfer coefficient using the heat flow meter method. *Energy Build* 2015;86:754–65. <https://doi.org/10.1016/j.enbuild.2014.11.005>.
- [11] Gaspar K, Casals M, Gangolells M. Energy & Buildings In situ measurement of façades with a low U-value: Avoiding deviations. *Energy Build* 2018;170:61–73.



- <https://doi.org/10.1016/j.enbuild.2018.04.012>.
- [12] Ahmad A, Maslehuddin M, Al-Hadhrami LM. In situ measurement of thermal transmittance and thermal resistance of hollow reinforced precast concrete walls. *Energy Build* 2014;84:132–41. <https://doi.org/10.1016/j.enbuild.2014.07.048>.
- [13] Litti G, Khoshdel S, Audenaert A, Braet J. Hygrothermal performance evaluation of traditional brick masonry in historic buildings. *Energy Build* 2015;105:393–411. <https://doi.org/10.1016/j.enbuild.2015.07.049>.
- [14] Grubeša IN, Teni M, Krstić H, Vračević M. Influence of freeze/thaw cycles on mechanical and thermal properties of masonry wall and masonry wall materials. *Energies* 2019;12:1–11. <https://doi.org/10.3390/en12081464>.
- [15] Bienvenido-Huertas D, Rodríguez-Álvaro R, Moyano JJ, Rico F, Marín D. Determining the U-Value of Façades Using the Thermometric Method: Potentials and Limitations. *Energies* 2018;11:1–17. <https://doi.org/10.3390/en11020360>.
- [16] Kim S-H, Lee J-H, Kim J-H, Yoo S-H, Jeong H-G. The Feasibility of Improving the Accuracy of In Situ Measurements in the Air-Surface Temperature Ratio Method. *Energies* 2018;11:1–18. <https://doi.org/10.3390/en11071885>.
- [17] International Organization for Standardization. ISO 6946:2007 - Building components and building elements - Thermal resistance and thermal transmittance - Calculation method. Geneva, Switzerland: 2007.
- [18] Ficco G, Iannetta F, Ianniello E, D’Ambrosio Alfano FR, Dell’Isola M. U-value in situ measurement for energy diagnosis of existing buildings. *Energy Build* 2015;104:108–21. <https://doi.org/10.1016/j.enbuild.2015.06.071>.
- [19] Bienvenido-Huertas D, Rubio-Bellido C, Pérez-Ordóñez JL, Oliveira MJ. Automation and optimization of in-situ assessment of wall thermal transmittance using a Random Forest algorithm. *Build Environ* 2020;168. <https://doi.org/10.1016/j.buildenv.2019.106479>.
- [20] Bienvenido-Huertas D, Rubio-Bellido C, Solís-Guzmán J, Oliveira MJ. Experimental characterisation of the periodic thermal properties of walls using artificial intelligence. *Energy* 2020;203. <https://doi.org/10.1016/j.energy.2020.117871>.
- [21] Eduardo Torroja Institute for Construction Science. Constructive elements catalogue of the CTE. 2010.
- [22] Kurtz F, Monzón M, López-Mesa B. Energy and acoustics related obsolescence of social housing of Spain’s post-war in less favoured urban areas. The case of Zaragoza. *Inf La Construcción* 2015;67:m021. <https://doi.org/10.3989/ic.14.062>.
- [23] Domínguez-Amarillo S, Sendra JJ, Oteiza I. La envolvente térmica de la vivienda social. El caso de Sevilla, 1939 a 1979. Editorial CSIC: Madrid; 2016.
- [24] Dudoit S, Fridlyand J, Speed TP. Comparison of discrimination methods for the classification of tumors using gene expression data. *J Am Stat Assoc* 2002;97:77–87.
- [25] Larivière B, Van Den Poel D. Predicting customer retention and profitability by using random forests and regression forests techniques. *Expert Syst Appl* 2005;29:472–84. <https://doi.org/10.1016/j.eswa.2005.04.043>.
- [26] Breiman L. Bagging predictors. *Mach Learn* 1996;24:123–40.
- [27] Breiman L. Random forests. *Mach Learn* 2001;45:5–32. <https://doi.org/10.1023/A:1010933404324>.

- [28] Assouline D, Mohajeri N, Scartezzini JL. Large-scale rooftop solar photovoltaic technical potential estimation using Random Forests. *Appl Energy* 2018;217:189–211. <https://doi.org/10.1016/j.apenergy.2018.02.118>.
- [29] Zhou Y, Qiu G. Random forest for label ranking. *Expert Syst Appl* 2018;112:99–109. <https://doi.org/10.1016/j.eswa.2018.06.036>.